



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



SINIRLI VERİ SETİYLE SINIFLAMA
UYGULAMALARINA YENİ BİR YAKLAŞIM

Saim ERVURAL

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Mayıs-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Saim ERVURAL tarafından hazırlanan “Sınırlı Veri Setiyle Sınıflama Uygulamalarına Yeni Bir Yaklaşım” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik – Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Seral ÖZŞEN

.....

Danışman

Doç. Dr. Murat CEYLAN

.....

Üye

Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

.....

Üye

Dr. Öğr. Üyesi Hasan KOYUNCU

.....

Üye

Dr. Öğr. Üyesi Güzin ÖZMEN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması TÜBİTAK tarafından 215E019 numaralı proje ile desteklenmiştir

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Saim ERVURAL

Tarih:26/05/2021

ÖZET

DOKTORA TEZİ

SINIRLI VERİ SETİYLE SINIFLAMA UYGULAMALARINA YENİ BİR YAKLAŞIM

Saim ERVURAL

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat CEYLAN

2021, 104 Sayfa

Jüri

Prof. Dr. Seral ÖZŞEN

Doç. Dr. Murat CEYLAN

Dr. Öğr. Üyesi Hüseyin Oktay ALTUN

Dr. Öğr. Üyesi Hasan KOYUNCU

Dr. Öğr. Üyesi Güzin ÖZMEN

Doğumdan sonraki ilk yirmi sekiz gün yenidoğan periyodu olarak adlandırılmaktadır. Doğumsal anomaliler veya sonradan gelişen hastalıklar bu süre içinde ölüm oranının yüksek olmasına neden olmaktadır. Yenidoğan yoğun bakım ünitelerinde yer alan inkübatörlerde bakım ve tedavileri yapılan bebeklerin ani değişim gösterebilen vücut sıcaklıklarının hızla tespit edilmesi, sağlık durumlarının izlenmesinde önem kazanmaktadır. Yenidoğanda vücut ısısının ve termal simetrisinin değerlendirilmesi, sağlık koşullarının izlenmesinde ve potansiyel risklerin tahmin edilmesinde önemlidir. Zararsız ve temassız bir yöntem olan termografi ile uygun yapay zekâ teknikleri kullanılarak yenidoğandaki hastalıkları erken aşamada tespit etmek mümkün olabilir. İnkübatörler bebeklerin tedavi ve bakımlarının yapıldığı, sıcaklık, nem, oksijen gibi parametrelerin kontrol altında tutulduğu yaşam alanlarıdır. Hastalıklara karşı savunma mekanizmalarının gelişmemiş olması, solunum desteğine ve fizyolojik parametrelerinin izlendiği cihazlara bağlı bulunmaları, termal izolasyonun sağlanma gereksinimi gibi faktörler mevcuttur. Ayrıca bazı hastalık kategorilerine sık rastlanırken, bazı hastalıklar nadiren görülmektedir. Yenidoğan yoğun bakım ünitelerinde karşılaşılan vaka çeşitliliği ve yenidoğan görüntülemenin hassasiyetle uygulanma gerekliliğinden yenidoğanların konfor alanını bozmadan tüm hastalık gruplarında yeterli sayıda görüntü popülasyonu içeren veri tabanları oluşturulamamaktadır.

Tez çalışmasında az veri ile yenidoğan hastalıkları hakkında bilgi edinmeyi amaçlayan teknikler kullanılarak sınırlı sayıda veri içeren problemlere yönelik verimli sınıflama yöntemleri ve ön-tanı sistemleri geliştirilmiştir. Böylece veri sayısının yetersiz olduğu hastalıkların sınıflanması sağlanmıştır. Yeni doğan bebeklere ait tüm termogramlar Selçuk Üniversitesi, Tıp Fakültesi, Yeni Doğan Yoğun Bakım ünitesinde kaydedilmiş ve bir termal görüntü veri tabanı oluşturulmuştur. Geleneksel yapay zekâ yöntemlerine dayalı nesne sınıflama algoritmaları binlerce görüntü ve çok büyük veri kümeleri üzerinde eğitim gerektirirler. Sınıflama problemlerinde sık karşılaşılan durumlardan biri veri sayısının az olması ve bazı sınıflarda hiç verinin bulunmamasıdır. Bu problemin üstesinden gelebilmek için daha fazla veri toplamak gerekmektedir. Daha fazla veri toplamanın mümkün olmadığı durumlarda ise eldeki az miktarda veriyi çeşitli yollarla artırmak ve az veri ile öğrenmenin yollarını araştırmak gerekmektedir. Tez çalışmasında veri sayısının az ve dengesiz olması problemine karşılık verimli sınıflama yaklaşımları önerilmiştir. Bu kapsamda derin öğrenme ve veri artırma yaklaşımları ile kardiyovasküler hastalıklar, pulmoner anomaliler, nekrotizan enterokolit, intestinal atrezi, enfeksiyon hastalıkları ve özofagus atrezinin sınıflanması gerçekleştirilmiştir. İlk kez bu çalışma ile yenidoğan hastalıkları çok sınıflı olarak ele alınmış ve sınırlı sayıda veri örneği bulunan hastalıklar yüksek başarıyla ayırt edilmiştir. Yürütülen uygulamalar dört başlık altında

gerçekleştirilmiştir. Farklı evrişimli sinir ağıları modelleri ve Siyam sinir ağıları ile tek atış öğrenme yaklaşımı kullanılan çalışmalardan ilkinde tam bağlı ağ katmanında yapay sinir ağıları ve destek vektör makinesi kullanılan evrişimli sinir ağıları ile ‘abdominal ve renal hastalıklar’, ‘kardiyovasküler hastalıklar’ ve ‘pulmoner anomaliler’ veri artırma tekniklerinin yardımıyla %83 doğrulukla sınıflanmıştır. Önerilen ikinci yöntemde, dört hastalık sınıfı için altı farklı yaklaşım önerilmiş ve en yüksek doğruluk %94.55 olarak elde edilmiştir. Yenidoğanlarda en sık karşılaşılan durumlardan biri olan pulmoner anomalilerin belirlenmesi için yapılan çalışmada evrişimli sinir ağı modeli geliştirilmiş ve veri artırmanın etkileri incelenmiştir. Bu uygulamada 34 yenidoğandan alınan görüntüler üzerinde veri artırımının sınıflama doğruluğunu %84’ten %91’e yükselttiği tespit edilmiştir. Bir başka uygulamada ise Siyam sinir ağıları ve tek atış öğrenme yaklaşımı kullanılarak veri sayısının az olduğu hastalıkların (nekrotizan enterokolit, özofagus atrezisi ve intestinal atrezi vb.) tespitinde uzmanlara ön-tanı sağlamak için çok sınıflı sınıflama çalışması gerçekleştirilmiştir. İki farklı optimizasyon tekniği ve veri artırımı kullanılarak, 2 sınıflı ve 3 sınıflı değerlendirme yaklaşımlarında test edilen yöntem ile sadece birkaç örnek veri bulunan kritik hastalıklar sınıflanmıştır. Sinir ağı modeli tarafından hiç görülmeyen sınıfların test edilebildiği tek atış öğrenme yaklaşımı sonuçlarına göre katman-bazlı stokastik grayan inişi algoritması veri artırımı ile kullanıldığında ortalama %92.50 doğruluk değeri vermiştir. Hastalık türü baz alınarak çıkarılan sonuçlar enfeksiyon hastalıkları ve özofagus atrezide %100, intestinal atrezide %99.17, nekrotizan enterokolitte %94.17 doğruluk elde edildiğini göstermektedir.

Anahtar Kelimeler: Derin öğrenme, Evrişimli sinir ağıları, Hastalık tespiti, Makine öğrenmesi, Sınıflama, Termografi, Veri artırımı, Yenidoğan

ABSTRACT

PHD THESIS

A NEW APPROACH TO CLASSIFICATION APPLICATIONS WITH LIMITED DATASET

Saim ERVURAL

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Assoc. Prof. Dr. Murat CEYLAN

2021, 104 Pages

Jury

**Prof. Dr. Seral ÖZŞEN
Assoc. Prof. Dr. Murat CEYLAN
Asst. Prof. Dr. Hüseyin Oktay ALTUN
Asst. Prof. Dr. Hasan KOYUNCU
Asst. Prof. Dr. Güzin ÖZMEN**

The first twenty-eight days after birth is called the neonatal period. Congenital anomalies or diseases that develop later cause the mortality rate to increase during this period. Rapid detection of suddenly changing body temperatures of babies who are cared for and treated in incubators in neonatal intensive care units is important in monitoring their health status. Evaluation of body temperature and thermal symmetry in the newborn is important in monitoring health conditions and predicting potential risks. If thermography, which is a harmless and non-contact method, and appropriate artificial intelligence techniques are used together, it may be possible to detect neonatal diseases at an early stage. Incubators are living spaces where babies are treated and cared for, and parameters such as temperature, humidity, and oxygen are kept under control. For newborns, there are factors such as the immaturity of their immune systems against diseases, their dependence on respiratory support and devices where their physiological parameters are monitored, and the need for thermal insulation. In addition, while some disease categories are common, some diseases are rarely seen. Due to the variety of cases encountered in neonatal intensive care units and the necessity of applying newborn imaging carefully, databases containing sufficient number of image populations cannot be created in all disease groups.

In this thesis, using techniques aiming to obtain information about neonatal diseases with little data, pre-diagnosis systems have been developed with efficient classification methods for problems with limited data. Thus, the classification of diseases with insufficient data was provided. All thermograms of newborn babies were recorded in Selçuk University, Faculty of Medicine, Neonatal Intensive Care Unit, and a thermal image database was created. Classification algorithms based on traditional artificial intelligence methods require training on thousands of images and very large data sets. One of the common situations encountered in classification problems is the insufficient number of data. To overcome this problem, it is necessary to collect more data. In cases where it is not possible to collect more data, it is necessary to increase the small amount of data available in various ways and to search for ways to learn with fewer data. In the thesis, efficient classification approaches have been proposed in response to the problem of low and unbalanced data. In this context, cardiovascular diseases, pulmonary anomalies, necrotizing enterocolitis, intestinal atresia, infectious diseases, and esophageal atresia were classified with deep learning and data augmentation approaches. Neonatal diseases were considered in this study as multi-class for the first time and diseases with limited data samples were distinguished with high performance. Applications were carried out under four headings. Experiments using different convolutional neural network models and Siamese neural networks approach have been carried out. In the first of these experiments, 'abdominal & renal diseases', 'cardiovascular diseases' and 'pulmonary anomalies' were

classified with 83% accuracy with the help of data augmentation techniques with convolutional neural networks using artificial neural networks and support vector machines in the fully connected network layer. In the second method proposed, six different approaches are proposed to classify four diseases. The highest accuracy of 94.55% was obtained for this experiment. In the study conducted to determine pulmonary anomalies, one of the most common conditions in newborns, the convolutional neural network model was developed and the effects of data augmentation were examined. In this application, it was determined that data increase on images taken from 34 newborns increased the classification accuracy from 84% to 91%. In another application, a multi-class classification study was carried out to provide pre-diagnosis to experts in the detection of diseases (necrotizing enterocolitis, esophageal atresia, and intestinal atresia, etc.) using Siamese neural networks and one-shot learning approach. By using two different optimization techniques and data augmentation, critical diseases with only a few sample data were classified using the method tested in 2-class and 3-class evaluation approaches. According to the results of the one-shot learning approach where classes that are not seen by the neural network model can be tested, the layer-based stochastic gradient descent algorithm used with data enhancement gave an average accuracy of 92.50%. Results based on disease class show that 100% accuracy is achieved in infectious diseases and esophageal atresia, 99.17% in intestinal atresia, and 94.17% in necrotizing enterocolitis.

Keywords: Classification, Convolutional neural networks, Data augmentation, Deep learning, Disease detection, Neonatal, Machine learning, Thermography



ÖNSÖZ

Doktora tez çalışmalarımda en çok emeği geçen, çok değerli yardım ve yönlendirmelerini eksik etmeyen, danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Öğretim Üyesi Sayın Doç. Dr. Murat Ceylan'a katkılarından dolayı şükranlarımı sunarım.

215E019 numaralı proje kapsamında bu tez çalışmasına destek veren TÜBİTAK'a, yenidoğan bebeklere ait görüntülerin kaydedilmesi, etiketlenmesi ve elde edilen sonuçların değerlendirilmesi aşamalarında katkı sunan Prof. Dr. Hanifi Soylu ve Doç. Dr. Murat Konak'a, Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesi personeline ve ilgili TÜBİTAK projesinde bursiyer olarak görev alan Yüksek Mühendis Ahmet Haydar Örnek'e teşekkür ederim.

Son olarak, hayatımın her adımında desteklerini hep hissettiğim kıymetli aileme, sevgisiyle beni cesaretlendiren, ilham veren eşim Yüksek Mühendis Sümeyra Ervural'a ve en büyük motivasyon kaynağım olan kızım Sare Mina'ya en içten minnet duygularıyla teşekkürü bir borç bilirim.

Saim ERVURAL
KONYA-2021

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	8
3. MATERYAL VE YÖNTEM.....	12
3.1. Yenidoğan Termal Görüntü Veri Tabanının Oluşturulması	12
3.1.1. YYBÜ’nde karşılaşılan olgular	15
3.1.2. Termal görüntülemeye deneysel standartlar	19
3.1.3. Termogramların kaydedilme biçimleri	20
3.1.4. Görüntü ön işleme.....	21
3.2. Yapay Zekâ ve Derin Öğrenme Yaklaşımları.....	23
3.2.1. Yapay sinir ağları.....	24
3.2.2. Destek vektör makinesi.....	26
3.2.3. Evrişimli sinir ağları	27
3.2.4. Siyam sinir ağları	38
3.3. Veri Artırımı Teknikleri.....	43
3.4. Değerlendirme Kriterleri.....	44
3.4.1. K-katlamalı çapraz doğrulama yöntemi.....	47
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	49
4.1. Kardiyovasküler Hastalıklar, Pulmoner Anomaliler ve Abdominal & Renal Hastalıkların Evrişimli Sinir Ağları ile Sınıflanması.....	49
4.1.1. Oluşturulan 4 sınıflı veri seti	49
4.1.2. Sınıflama görevleri ve ESA modeli	52
4.1.3. ESA ile kardiyovasküler hastalıklar, pulmoner anomaliler ve abdominal & renal hastalıkların sınıflanması uygulamasının sonuçları	56
4.2. Evrişimli Sinir Ağları ve Veri Artırımı Teknikleri Kullanılarak Yenidoğan Hastalıklarının Çok-Sınıflı Olarak Belirlenmesi	59
4.2.1. Sınıflama yaklaşımları	62
4.2.2. ESA ve veri artırımı teknikleri ile çok sınıflı sınıflama uygulamasında kullanılan ağ modeli.....	66
4.2.3. ESA ve veri artırımı ile yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi uygulamasının sonuçları	68
4.3. Sınırlı Termal Veri ile Yenidoğanlarda Solunum Sistemi Anomalilerinin Diğer Hastalıklardan Ayırt Edilmesi	71
4.3.1. Kullanılan veri seti.....	71

4.3.2. Uygulamada kullanılan ağ modeli	74
4.3.3. Sınırlı veri ile yenidoğan pulmoner anomalilerinin diğer hastalıklardan ayırt edilmesi uygulamasının sonuçları.....	75
4.4. Derin Siyam Ağları ve Tek Atış Öğrenme ile Sınırlı Termal Veri seti Kullanarak Yenidoğan Hastalıklarının Sınıflanması	77
4.4.1. Kullanılan veri seti ve veri artırma teknikleri.....	77
4.4.2. SSA ile tek atış öğrenme uygulaması	81
4.4.3. Derin SSA modeli	82
4.4.4. Optimizasyon algoritmaları	83
4.4.5. Uygulama sonuçları	84
5. SONUÇLAR VE ÖNERİLER	90
5.1. Sonuçlar	90
5.2. Öneriler	96
KAYNAKLAR	98

SİMGELER VE KISALTMALAR

Simgeler

b	: Bias değeri
B	: Renkli görüntünün mavi bandı
$B(i, j)$	: Parlaklık artırma
c	: Işık hızı
cm	: Santimetre
C	: Kayma parametresi
$C(i, j)$	: Karşıtlık değiştirme
$^{\circ}C$	: Santigrat derece
d	: Polinomun derecesi
$do(X, Y)$	: Doğrusal fonksiyon
D	: Veri seti boyutu
η	: Öğrenme oranı
n_{ϕ}	: Özellik matris boyutu
e_k	: Dolgu ekleme parametresi
f_i	: Filtre boyutu
γ	: Fonksiyonun ayarlanabilir parametresi
G	: Renkli görüntünün yeşil bandı
$G(i, j)$	: RGB-gri seviye dönüşümü
h	: Planck sabiti
H	: Hata fonksiyonu
k	: Boltzmann sabiti
k	: Filtre kaydırma parametresi
km	: Kilometre
K	: Derece kelvin
λ	: Dalga boyu
μm	: Mikrometre
m	: Metre
mm	: Milimetre
$M(\lambda, T)$	: Maksimum yayma gücü
$po(X, Y)$	: Polinomik fonksiyon
P	: Ağın benzerlik skoru
$P(\lambda, T)$	: Maksimum foton miktarı
ρ	: Maksimum marjin
$rad(X, Y)$	: Radyal fonksiyon
R	: Renkli görüntünün kırmızı bandı
σ	: Sigmoid aktivasyon fonksiyonu
$S(i, j)$	: Keskinleştirme
T	: Mutlak sıcaklık
$\varphi(\bullet)$	: Aktivasyon fonksiyonu
$\vec{x}$	: Girdi vektörü,
χ_1, χ_2	: Yapay sinir ağının girdileri
$X \bullet Y$	: X ve Y için iç çarpım
ω, ω_i	: Ağırlık değerleri
$\vec{w}$	: Çoklu düzlemin normali (ağırlık vektörü)
$\ \vec{w}\ $	: w 'nın Öklid formu

Kısaltmalar


AK	: Aort koarktasyonu
ASD	: Atriyal septal defekt
BT	: Bilgisayarlı tomografi
DIN	: Alman standartlar enstitüsü
DN	: Doğru negatifler
DP	: Doğru pozitifler
DVM	: Destek vektör makinesi
EnfH	: Enfeksiyon hastalıkları
ESA	: Evrişimli sinir ağları
FIR	: Uzak kızılötesi
HSK	: Hipoplastik sol kalp sendromu
İA	: İntestinal anomaliler
İAtr	: İntestinal atrezi
İO	: İntestinal obstrüksiyon
IUGR	: Gelişim geriliği
k-NN	: k-en yakın komşu
KA	: Karar ağaçları
Kb-SGİ	: Katman bazlı stokastik gradyen inişi
KrdH	: Kardiyovasküler hastalıklar
KKH	: Konjenital kalp hastalığı
LR	: Lojistik regresyon
LWIR	: Uzun dalga kızılötesi
MR	: Manyetik rezonans
NB	: Naive bayes
NEC	: Nekrotizan enterokolit
MWIR	: Orta dalga kızılötesi
NIR	: Yakın kızılötesi
ÖA	: Özofagus atrezisi
PAB	: Pulmoner arter banding
PDA	: Patent duktus arteriosus
PRM	: Prematürite
PA	: Pulmoner anomaliler
PH	: Pulmoner hipertansiyon
RDS	: Solunum sıkıntısı sendromu
RGB	: 3 boyutlu renk uzayı
RO	: Rasgele orman
RSV	: Respituar sinsitiyal virüsü
SSA	: Siyam sinir ağları
SWIR	: Kısa dalga kızılötesi
TTN	: Geçici taşipne
VSD	: Ventriküler septal defekt
YN	: Yanlış negatifler
YP	: Yanlış pozitifler
YSA	: Yapay sinir ağları
YYBÜ	: Yenidoğan yoğun bakım ünitesi

1. GİRİŞ

Kızılötesi termal görüntülemenin non-invazif, iyonize olmayan, zararsız ve hızlı bir yöntem olması yenidoğan yoğun bakım ünitesinde bulunan bebeklerin vücut sıcaklıklarının onlara herhangi bir rahatsızlık vermeden sürekli olarak izlenip değerlendirilmesi; acil müdahale ihtiyacı, yeni tedavi planlaması veya stabil durumun korunması gibi hayati süreçlerde kullanım gerekliliğini ortaya çıkarmıştır. Vücudun sıcaklık dağılımında ortaya çıkan asimetrielerin anormalliklere işaret etmesi, termal görüntüler kullanılarak bir ön-tanı sisteminin kurgulanabileceği fikrini ortaya çıkarmıştır. Bebeklerdeki fizyopatolojik değişimlere dayanan termal görüntüleme ve ön-tanı işlemi bir kızılötesi kamera ile vücut sıcaklığının haritasını çıkararak termogram adı verilen görüntülerin alınmasına ve bu görüntülerin yapay zekâ teknikleri kullanılarak ön analizinin yapılmasına dayanmaktadır. Normal vücutta termal olarak simetri olduğundan asimetrik sıcaklıklar görüntüler üzerinde kolaylıkla fark edilebilecektir. Yenidoğan yoğun bakım ünitelerindeki (YYBÜ) bebeklerin hastalıklara karşı savunma mekanizmalarının çok gelişmemiş olması, sıcaklık dengelerinin korunması için yatırıldıkları inkübatörlerden uzaklaştırılamamaları, birçoğunun oksijen desteğine bağlı olması, farklı fizyolojik parametrelerinin izlendiği cihazlara bağlı bulunmaları gibi faktörler mevcuttur. Yenidoğan yoğun bakım ünitelerinin bu hassas durumu göz önüne alındığında geleneksel yapay zekâ yöntemlerinin ihtiyaç duyduğu binlerce hatta onbinlerce görüntüden oluşan termal görüntü veri tabanını oluşturmak mümkün olmamaktadır. Bu durum, yapay zekâ tabanlı biyomedikal uygulamalar için yaygın bir problemdir. Bu tez kapsamında termal görüntülerin oluşturduğu sınırlı (dengesiz sınıf dağılımı ve az veri sayısı) veri setiyle yenidoğan hastalıklarının erken teşhisi için gerekli ön işleme, veri artırma, sınıflama süreçleri önerilmiştir. Böylece YYBÜ’de gözlem/tedavi altında tutulan bebeklerde nadir karşılaşılan ve az sayıda veri örneği bulunan yenidoğan hastalıkları tespit edebilir olacaktır.

Termal görüntülemenin insan vücudu üzerindeki etkileri ve vücuttan yayılan kızılötesi radyasyonu algılama sistematliğini değerlendirebilmek için nesnelerden yayılan radyasyon fizikini incelemek gerekmektedir. Mutlak sıfır noktası (-273.15°C , 0°K) üzerinde tüm nesneler, sıcaklıklarına ve spektral emisivitelerine bağlı olarak kızılötesi radyasyon yayma yeteneğine sahiptir (Rogalski ve Chrzanowski, 2002; Knobel ve ark., 2011). Dalga boyu $0.75\text{ }\mu\text{m}$ ile $1000\text{ }\mu\text{m}$ arasında olan kızılötesi radyasyon, elektromanyetik spektrumda görünür ışık ve mikrodalga bölgelerinin arasında bulunur

(Knobel ve ark., 2011). Görünür ışık spektrumunun en uzun dalga boyu olan kırmızı ışığın ötesinde bir bölgeye karşılık gelmesinden dolayı “Kızılötesi” olarak ifade edilmektedir. Elektromanyetik spektrumun dalga boylarına göre ayrılmış bölgeleri ve kızılötesi bandının spektrumdaki yeri Şekil 1.1’de gösterilmiştir. Oldukça geniş bir spektrumda yayılım yapan nesnelerin yaydığı radyasyonu algılayan sistemler tayfin tümünü algılama yeteneğine sahip değildir. Algılayıcıların kapasiteleri nedeniyle kızılötesi spektrumda alt bantlar oluşturulmuştur. Alman Standartlar Enstitüsü (DIN) tarafından belirlenen bölümlene biçimine göre kızılötesi alt-bantlar Çizelge 1.1’de verilen bölümlerle ifade edilmektedir.



Şekil 1.1. Elektromanyetik spektrum ve kızılötesi bant (Knobel ve ark., 2011)

Çizelge 1.1. Kızılötesi alt-bantları ve dalga boyları (Byrnes, 2008)

Kızılötesi alt-bantları	Dalga boyu
Yakın Kızılötesi (NIR)	0.75 μm – 1.4 μm
Kısa Dalga Kızılötesi (SWIR)	1.4 μm – 3 μm
Orta Dalga Kızılötesi (MWIR)	3 μm – 8 μm
Uzun Dalga Kızılötesi (LWIR)	8 μm – 15 μm
Uzak Kızılötesi (FIR)	15 μm – 1 mm

Bir kara cisim için termal radyasyon gücünün (veya yayılan foton sayısı) dalga boyu ile değişimi. Planck’ın radyasyon yasasına göre tanımlanmaktadır (Eşitlik 1.1 ve Eşitlik 1.2).

Kara cisim için maksimum yayma gücü:

$$M(\lambda, T) = \frac{2\pi hc^2}{\lambda^5} \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]^{-1} \left(\frac{\text{Watt}}{\text{cm}^2 \mu\text{m}} \right) \quad (1.1)$$

Maksimum foton miktarı:

$$P(\lambda, T) = \frac{2\pi h}{\lambda^4} \left[\exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]^{-1} \left(\frac{\text{photons}}{s} \text{cm}^2 \mu\text{m} \right) \quad (1.2)$$

Bu eşitliklerde; dalga boyu λ , mutlak sıcaklık T , ışık hızı c , Planck Sabiti h ($6.6256 \times 10^{-34} \text{ Ws}^2$), Boltzmann sabiti ise k ($1.38054 \times 10^{-23} \text{ JK}^{-1}$) ile ifade edilmektedir.

Maksimum güç;

$$\lambda_{mw} T = 2898 \mu\text{mK} \quad (1.3)$$

Maksimum foton;


$$\lambda_{mp} T = 3670 \mu\text{mK} \quad (1.4)$$

Maksimum yayılım dalga boyu, Wien'in yer değiştirme kanunu ile ifade edilmektedir ve nesnenin mutlak sıcaklığı ile maksimum yayılım dalga boyu ters orantılıdır (Eşitlik 1.3 ve Eşitlik 1.4).

Elektromanyetik dalgalar atomların ve tüm yüklü parçacıkların titreşimi ile üretilir. Bir nesnenin atomlarının titreşim hızı sıcaklığa doğrudan etki etmektedir ve spektral yayılım enerjisi titreşim hızı arttıkça artar. İnsan vücudu da diğer tüm nesneler gibi sürekli titreşen atomlardan oluşur. Vücudun yaydığı radyasyon miktarı, elektromanyetik spektrumun kızılötesi alanı içindedir ve dalga boyu 0.75-1000 mikrometre aralığındadır (Sruthi ve Sasikala, 2015). Deri emisivitesi, cilt sıcaklığını belirlemek için önemli bir unsurdur ve dalga boyuna bağlı olarak 0-1 arasında değerlendirir (Bouzida ve ark., 2009). İnsan derisinin emisivitesi ise 0.96-0.98 arasındadır bu nedenle neredeyse bir kara cisim gibi davranır (Ring ve Bacon, 1977). Bu nedenle, insan derisinin yayma gücü bir kara cismin yayma gücüne yakındır. Görüntüleme teknolojilerinde

yaşanan gelişmelerin ardından gözün göremediği dalga boylarındaki (0 – 380 nm ve 780 – 25000 nm) ışınımın görüntüleme araçları vasıtasıyla görülebilir hale gelmiştir.

Deriden yayılan kızılötesi radyasyon, termal görüntüleme kullanılarak doğrudan sıcaklık değerlerine dönüştürülebilir. Termal kameralar, kızılötesi enerjiyi elektronik sinyallere dönüştürür, bu sinyaller iki boyutlu bir dizide düzenlenmiş pikseller olarak görüntülerle ifade edilir (Knobel ve ark., 2011; Hildebrandt ve ark., 2012). Her piksel, görüntülenen bölgenin sıcaklık değerlerini temsil eder (Sruthi ve Sasikala, 2015). Termal kameralar tarafından üretilen görüntüler termogram olarak adlandırılır. Örnek bir yenidoğan termogramı Şekil 1.2’de gösterilmiştir. Termogramların sıcaklık değerleri görsel olarak gri seviyede veya farklı renk paletlerinde görüntülenebilir. Böylece incelenen nesnenin yüzeyindeki sıcaklık dağılımının farklı renk tonlarıyla görsel olarak görülmesi sağlanır. Renklerin dağılımı, vücut yüzeyinden yayılan kızılötesi radyasyon miktarındaki azalma ya da artışı gösterir. Medikal termografide termogramlar, kızılötesi radyasyonu yakalayıp organların ve dokuların sıcaklık dağılımını ölçmek için kullanılır. Termal görüntüleme insan vücudu cilt yüzeyinin geniş alanlarının kaydedilmesine ve haritalanmasına izin verir, böylelikle fizyolojik bozuklukların neden olduğu sıcaklık değişiklikleri hastaya herhangi bir rahatsızlık ve radyasyon hasarı vermeden tespit edilebilir (Sruthi ve Sasikala, 2015).



Şekil 1.2. Örnek yenidoğan termogramı

Vücutta oluşan fizyolojik fonksiyon bozuklukları, sıcaklık artışlarına neden olur. Bu artışlar, kızılötesi görüntülerde sıcak noktalar veya asimetric desenler olarak gösterilir. Sağlıklı bir insanda cilt sıcaklığının dağılımı kontralateral simetri gösterir.

Belirli bir düzeyin üzerindeki asimetri ile sıcaklık dağılımı genellikle anormalliklerin güvenilir bir göstergesidir (Jones, 1998). Bu nedenle, sağlıklı vücut termal olarak simetrik olduğundan, asimetrik sıcaklıklar görüntülerden tespit edilebilir. Şekil 1.3'te belirgin termal asimetri gösteren bir insan vücudunun termogramı verilmiştir. 50'li yılların ortalarından beri klinik pratikte ve vasküler, nörolojik, kas-iskelet sistemleri gibi çeşitli alanlardaki araştırmalarda kullanılmaktadır (Ring ve Ammer, 2012).



Şekil 1.3. Asimetrik termal dağılım gösteren vücut termogramı (Marins ve ark., 2015)

Yeni doğan bebeklerin hastalıklarının erken teşhis edilmesi ve tedavi süreçlerinin izlenmesi, sağlık durumlarının korunması bakımından büyük önem taşımaktadır (Nur, 2014). Bu durum göz ardı edilirse yenidoğan sağlık durumlarının hızlı bir şekilde bozulmasına ve ölüme neden olabilir. Nitekim Dünya Bankası ve Dünya Sağlık Örgütü'nün de yer aldığı BM Kurumlar Arası Çocuk Ölümleri Tahmin Grubu tarafından yapılan araştırmanın raporlarına göre, her bin bebekten 18'i doğumdan sonraki ilk 28 günlük süreçte (yenidoğan evresi) hayatını kaybetmektedir. Yine aynı rapora göre, tüm yenidoğan ölümlerinin yaklaşık üçte biri doğumdan sonraki ilk 24 saatte ve dörtte üçü yaşamın ilk haftasında meydana gelmektedir (Hug ve ark., 2019). Bu nedenle tıbbi gözlem, muayene ve müdahalenin gecikmeden, hızlı ve güvenilir bir şekilde

gerçekleştirilmesi hayati önem taşımaktadır. Kızılötesi termal görüntülemenin non-invazif, iyonize olmayan, zararsız ve hızlı bir yöntem olması dolayısıyla yenidoğan yoğun bakım ünitesinde kullanılması önem kazanmaktadır. Vücudun sıcaklık dağılımında ortaya çıkan asimetrielerin anormalliklere işaret etmesi, termal görüntüler kullanılarak bir ön-tanı sisteminin kurgulanabileceği fikrini ortaya çıkarmıştır. Bebeklerdeki fizyopatolojik değişimlere dayanan termal görüntüleme ile ön-tanı işlemi, bir kızılötesi kamera ile vücut sıcaklığının haritasını çıkararak termogram adı verilen görüntülerin kaydedilmesine ve bu görüntülerin makine öğrenmesi kullanılarak sınıflanmasına dayanmaktadır. Normal vücutta termal olarak simetri olduğundan asimetrik sıcaklıklar görüntüler üzerinde fark edilebilecektir.

Yapay zekâ ve makine öğrenmesindeki gelişmelerle birlikte, uzmanların yorumlarına dayalı sonuçları desteklemek için otomatik karar sistemleri ortaya çıkmıştır. Uzmanlar tarafından etiketlenen veriler bu sistemlerin temelini oluşturur. Yapay zekâ tabanlı algoritmalar, temelde hangi sınıfa ait olduğunu bilinen verilerden özellik çıkarma ve özellik seçme işlemlerini yaparak otomatik sınıflama gerçekleştirir. Evrişimli sinir ağları (ESA), son yıllarda yaygınlaşan derin öğrenme yöntemlerinden biridir. Görüntü işleme alanında ESA'lar, nesne tanıma, gürültü giderme, segmentasyon, veri artırma gibi uygulamalarda kullanılmaktadır.

Günümüzde bilgisayarlı tomografi (BT) ve manyetik rezonans (MR) görüntüleme yenidoğanda tanı amaçlı kullanılmaktadır (Vyas ve ark., 2012). Geleneksel görüntüleme yöntemlerinde bebeklerin inkübatörden çıkarılıp radyoloji bölümüne alınması veya bir görüntüleme cihazına aktarılması gerekmektedir. Görüntüleme sırasında ısı izolasyonun zarar görmesi hipotermiye neden olabilmekte ve bazı durumlarda doğru nefes tutmayı kolaylaştırmak için anestezi gerekmektedir (Taylor, 2008). Ek olarak, BT ve MR görüntüleme tüm vücutta değil, genellikle lokal olarak yapıldığından, görüntülenmeyen alanlardaki anormallikler gözden kaçabilmekte ve BT'de yenidoğanlar zararlı radyasyona maruz kalmaktadır. Bebeklerin çoğu solunum desteklerine, oksijen satürasyonunun ve nabızın gözlendiği sensörlere bağlı olduğundan inkübatörlerden çıkarılmaları uygun değildir. Tüm bu olumsuzluklar göz önüne alındığında, geleneksel görüntüleme teknikleri yenidoğan yoğun bakım üniteleri için işlevsiz kalmaya devam etmektedir (Goetz ve ark., 2005). Termal görüntüleme ile herhangi bir radyasyon ve cerrahi müdahaleye gerek kalmadan yoğun bakım ünitesinde erken hastalık tanısına imkân sağlamakta veya yenidoğanların tedavi süreci izlenebilmektedir. Diğer görüntüleme teknikleriyle karşılaştırıldığında, termal görüntülemenin en önemli avantajları, tüm vücut yüzeyine

odaklanarak termal asimetriyi saptama ve hastalığı invaziv olarak teşhis etme kabiliyetidir (Jones, 1998). Yenidoğan yoğun bakım ünitelerindeki bebeklerin hastalıklara karşı savunma mekanizmalarının çok gelişmemiş olması, sıcaklık dengelerinin korunması için yatırıldıkları inkübatörlerden uzaklaştırılamamaları, birçoğunun oksijen desteğine bağlı olması, farklı fizyolojik parametrelerinin izlendiği cihazlara bağlı bulunmaları gibi faktörler göz önüne alındığında yapay zekâ yöntemlerinin ihtiyaç duyduğu binlerce görüntüden oluşan termal görüntü veri tabanını oluşturmak mümkün olmamaktadır.

Bu tez çalışmasında odaklanılan yenidoğan hastalıklarına yönelik görüntüler, TÜBİTAK tarafından desteklenen 215E019 numaralı “Yenidoğan Yoğun Bakım Üniteleri İçin Termal Görüntüleme Tabanlı Ön-Teşhis Sistemi” projesi kapsamında Selçuk Üniversitesi Tıp Fakültesi Yenidoğan Yoğun Bakım Ünitesinden alınmıştır. Yaklaşık bir yıllık bir süre içerisinde toplamda ise 39 farklı hastalık sınıfından 163 vaka ile karşılaşmıştır. Bu durum sınıflanması planlanan hastalık türlerinin temel sınıflama algoritmaları kullanılarak sınıflanması için yeterli sayıda ve nitelikte veri seti oluşturmanın zor olduğunu kanıtlamaktadır.

Tez kapsamında yürütülen çalışmalar, sınırlı veri içeren yenidoğan termal görüntü veri tabanı özelinde gerçekleştirilmiştir. Derin öğrenme, görüntü işleme ve veri artırımı teknikleri kullanılarak yenidoğan yoğun bakım ünitelerinde karşılaşılan hastalıklar için ön-tanı sistemleri önerilmiştir. Yenidoğan yoğun bakım ünitelerine yönelik gerçekleştirilen çalışmaların, farklı sınırlı veri problemlerinin çözümünde kullanılabilirliği desteklenmektedir.

2. KAYNAK ARAŞTIRMASI

Kızılötesi termografinin kavramı, Sir William Herschel (Herschel, 1800) tarafından kızılötesi radyasyonun keşfi ile doğmuştur. Kızılötesi sensörlerin geliştirilmesi ve ardından 1940'larda kızılötesi kameraların ortaya çıkması ile uygulama alanı bulmuştur (Lloyd, 2013). II. Dünya Savaşı sırasında askeri amaçlarla kullanılmaya başlanan kızılötesi termografi (Henneke ve ark., 1979), sivil kullanıma açıldıktan sonra tahribatsız muayene yöntemlerinde, özellikle yüzey ve yüzey altı kusurlarını belirlemeye yönelik çalışmalarda (Henneke ve ark., 1979; Maldague, 2001; Modest, 2013) ve tıbbi uygulamalarda hastalıklara bağlı anormal termal paternlerin tespiti için kullanılmıştır. Barnes gerçekleştirdiği ilk tıbbi çalışmada, cilt yüzeyinin spektral bölgede mükemmel bir kızılötesi radyasyon yayıcısı olduğunu ve bir sıcaklık haritası olarak kaydedilebileceğini bildirmiştir. Sonuç olarak, insan-vücut sıcaklığı haritalarından elde edilen fiziksel anormalliklerin hastalık tespitinde kullanılabileceğini vurgulamıştır (Barnes, 1963). 1966'da yayınlanan çalışmada Sherman ve ark. insan vücudunun eşleştirilmiş organları arasındaki termal asimetriyi değerlendirmek için termografiyi kullanmıştır (Sherman ve ark., 1996). Sonraki yıllarda, noninvaziv, zararsız ve temassız bir yöntem olan termografinin, üroloji (Rasor ve ark., 1993; Ng ve ark., 2009), meme kanseri tespiti (Thompson ve ark., 1978; Zhong-Shan ve Jing, 2005; Amalu ve ark., 2006; Arora ve ark., 2008; Kontos ve ark., 2011), termoregülasyon (Jones, 1998; Bouzida ve ark., 2009; Dail ve ark., 2011), vasküler hastalıklar (Bagavathiappan ve ark., 2008), beyin görüntüleme (Shevelev, 1998), romatolojik hastalıklar (Cosh ve Ring, 1970; Will ve ark., 1992; Cherkas ve ark., 2003) gibi pek çok uygulaması gerçekleştirilmiştir.

Yenidoğanlarda termal görüntüleme ile ilgili çalışmalar termal görüntüleme sistemleri aracılığıyla yapılan uygulamalar için incelenmiştir. Yüzey termometreleri ile yapılan ölçümlere dayalı çalışmalar bu literatür taramasına dahil edilmemiştir. Yenidoğanlarda termal görüntüleme alanındaki ilk çalışmalar 70'li yılların sonlarında yapılmıştır. Pomerance ve ark. bebeklerin ön ve arka termogramlarından vücut yüzeyindeki sıcak ve soğuk bölgeleri analiz ederek iç organların rutin taramasını yapmış ve böbrek malformasyonlarını tespit etmişlerdir (Pomerance ve ark., 1977). Clark ve Stothers tarafından yayınlanan çalışmada, yenidoğanlarda cilt sıcaklığı dağılımının analizi farklı klinik senaryolarda gerçekleştirilmiştir (Clark ve Stothers, 1980). Bebeklerin sıcaklık değerlerinin hem termokupl hem de termal kamera ile kaydedildiği

çalışmada her iki modalitenin verdiği değerlerin ortalama karesel hatası karşılaştırılmıştır. Oya ve ark. rutin yenidoğan bakımı alan yenidoğanlarda termojenik aktivitede normal fizyolojik değişiklikler gözlemlendiğini vurgulamıştır (Oya ve ark., 1997).

Yenidoğan termal görüntüleme ile ilgili çalışmaların sayısı son yirmi yılda artmıştır. 2003 yılına gelindiğinde Christidis ve ark. doğumdan sonraki ilk saatin termal analizini yapmıştır. Bu çalışmada doğumdan kısa bir süre sonra vücut içindeki sıcaklık korunurken periferik bölgelerin hızla soğuduğu raporlanmış ve bu durumu önlemek için bebeğin ılık su ile yıkanması veya anne ile cilt temasında bulunması gerektiği belirtilmiştir (Christidis ve ark., 2003). Abbas ve Leonhardt tarafından yapılan çalışmada, bağımsız bileşen analizi hibrit modeli algoritmasına dayalı olarak yenidoğanların cildinin termal örüntü sınıflaması yapılmıştır (Abbas ve Leonhardt, 2008). Saxena ve Villital, pediatrik popülasyonda termografinin klinik uygulamalarının fizibilitesini değerlendirmiş ve teşhis edilebilecek patolojik durumları belirlemeyi amaçlamıştır (Saxena ve Willital, 2008). 2010 yılında, nekrotizan enterokolit (NEC) tanısı koyulan bebeklerin vücut ısı ile NEC hastalığı arasındaki korelasyon Rice ve ark. tarafından incelenmiştir (Rice ve ark., 2010). Bu çalışma kapsamında termografinin çok düşük ağırlıklı bebeklerin görüntülenmesi için uygunluğu, bebeklerin abdomen ve göğüs sıcaklık değerlerinin karşılaştırılması ve abdomen sıcaklığı ile NEC hastalığı arasındaki ilişkinin ortaya çıkarılması üzerinde durulmuştur. Elde edilen sonuçlar NEC hastalığına sahip bebeklerin abdomen sıcaklığının sağlıklı bebeklere göre daha az olduğunu göstermektedir. Herry ve ark. NEC hastalığı tanısı için yüzeysel karın sıcaklıklarını değerlendiren regresyon analizi yöntemini kullanarak sınıflama çalışması yürütmüştür (Herry ve ark., 2011). Abbas ve ark. yenidoğan bebeklerin farklı senaryolarda oluşabilecek hatalı termal ölçüm durumlarına karşı düzeltme teknikleri önermiştir (Abbas ve ark., 2012). Görüntüleme esnasında harici ısıtıcı kaynakları, hava akışı ve arka plan sıcaklığı gibi dış etkenlerin sıcaklık ölçümlerinde bozucu etki yaptığı belirtilen bu çalışmada matematiksel yaklaşımlar ile sorunların giderilmesine çalışılmıştır. Frize ve ark. NEC hastalığı olan bebekleri tespit etmek için termografiyi kullanmıştır (Frize ve ark., 2013). Heimann ve ark. sıcaklık dağılımı hakkında ayrıntılı bilgi için 10 prematüre bebeğin farklı vücut bölgelerindeki cilt sıcaklığını değerlendirmiştir. Bu çalışmada erken doğan bebeklerde cilt yüzeyindeki termal dağılım kayıt edilerek lokal olarak karşılaştırılmıştır (Heimann ve ark., 2013). Nur, yenidoğanda NEC hastalığının erken teşhisi için otomatik bir yöntem uygulamış ve NEC'li bebekler ile sağlıklı bebeklerin termal asimetri derecesinin birbirinden farklı olduğunu ortaya koymuştur (Nur, 2014).

Kurath-Koller ve ark. lazer akupunktur sırasında yenidoğanlarda cilt sıcaklığındaki termal değişiklikleri değerlendirmek için termal görüntülerden faydalanmıştır (Kurath-Koller ve ark., 2015). Knobel-Dail ve ark. prematüre bebeklerde vücut sıcaklığını ölçmek için bölgesel olarak kızılötesi termografinin yararını araştırmıştır. Bu bağlamda bölgesel olarak sıcaklık farklılıkları termografi ve termistör ile ölçülerek termografi başarımının gösterilmesi amaçlanmış ve ilk 12 saat içerisinde ayak sıcaklık değerlerinin abdomen sıcaklık değerlerinden daha yüksek olduğu kanıtlanmıştır. (Knobel-Dail ve ark., 2017). Bach ve ark. cilt ısısının ve cildin vazodilatasyonunun yenidoğanlarda uyku eğilimini etkileyip etkilemediğini araştırmak için termografiye başvurmuştur (Bach ve ark., 2019). Savaşçı ve Ceylan, yenidoğan yoğun bakım ünitesindeki bebeklerin hastalık tanısında hata oranını düşürmek için termografiye dayanan bir analitik sistem önermişlerdir (Savaşçı ve Ceylan, 2018). Elde edilen sonuçlar soldan-sağa ortalama, standart sapma, varyans ve çarpıklık değerlerinin hasta ve sağlıklı yenidoğanlarda farklı olduğunu ortaya koymuştur. Hasta yeni doğanlardaki termal asimetri derecesinin sağlıklı yeni doğanlardan daha yüksek olduğu gösterilmiştir. Örnek ve ark. termogramların değerlendirilmesinde kullanılacak doğru yaklaşımların tespitine yönelik bir çalışma ortaya koymuştur. Elde edilen sonuçlar sıcaklık haritalarındaki bozulma miktarının renkli (RGB) görüntülerdeki bozulma miktarından daha düşük olduğunu ve klasik yöntemler kullanıldığında RGB görüntüler yerine sıcaklık haritaları kullanımının daha etkili olduğunu vurgulamıştır (Ornek ve ark., 2018). Başka bir çalışmada ise yenidoğan termal görüntüleri ve makine öğrenmesini birleştirerek otomatik bir sağlıklı-hasta sınıflaması gerçekleştirmiştir. Çalışmada 38 bebekten alınan 3800 görüntü veri artırma ile 30400'e çıkarılmış ve %99.58 doğruluk elde edilmiştir (Ornek ve ark., 2019). Örnek ve Ceylan, VGG16 modeliyle transfer öğrenme uygulayarak açıklanabilir derin öğrenme tabanlı bir yenidoğan hastalık sınıflama çalışması ortaya koymuştur (Örnek ve Ceylan, 2020). Savaşçı ve ark. termal görüntüleme ve yapay sinir ağlarına dayalı sağlıklı-hasta sınıflama modeli geliştirmiş, yapay sinir ağları ve çoklu çözünürlüklü analizi hibrit modelini kullanmıştır (Savasci ve ark., 2019). Topalidou ve arkadaşları, 2019'da yayınladıkları incelemede, neonatal bakımda termal görüntüleme uygulamalarını ayrıntılı olarak ele almış ve karşılaştırmalı analizleri dahil etmiştir (Topalidou ve ark., 2019). Örnek ve ark. tarafından 2020'de yayınlanan çalışmada ise termal haritalardan yerel ikili desen ve hızlı korelasyon tabanlı filtre yaklaşımları ile özellik seçme uygulamış, KA, YSA, LR ve RO algoritmaları ile hasta-sağlıklı sınıflaması gerçekleştirilmiştir (Ornek ve ark., 2020). Ervural ve ark. gerçekleştirdikleri çalışmada evrişimli sinir ağları ile sınıflama

uygulamasında veri arttırma tekniklerinin sonuçlara etkilerini incelemiştir. (Ervural ve ark., 2020). Ervural ve Ceylan termal görüntülemenin yapay zekâ tabanlı biyomedikal uygulamalarını inceledikleri çalışmada yenidoğan hastalıklarının belirlenmesinde termografi uygulamalarını ayrıntılı olarak ele almıştır (Ervural ve Ceylan, 2021b). Ervural ve Ceylan gerçekleştirdikleri bir başka çalışmada sınırlı termal veri kullanarak yenidoğanda pulmoner anomalilerin belirlenmesine yönelik ESA tabanlı bir metodoloji kullanmıştır. Pulmoner anomalisi ile kardiyovasküler hastalıkları ve abdominal bölge anomalileri olan 34 yenidoğanın görüntüsünün değerlendirildiği çalışmada %91 doğruluk %80 duyarlılık ve %100 özgüllük ile iki sınıf birbirinden ayrılmıştır (Ervural ve Ceylan, 2021a).



3. MATERYAL VE YÖNTEM

Sınıflama problemlerinde karşılaşılan en temel problemlerden biri veri sayısının yetersiz olmasıdır. Tez çalışmasında bu problemlere uygulanmak üzere veri artırma, görüntü ön işleme, makine öğrenmesi ve derin öğrenme uygulamaları üzerinde durulmuştur. Çalışma, veri sayısının az olduğu ve sınıflar arası veri dengesizliği bulunan YYBÜ'den alınan termal görüntüler ile yenidoğan hastalıklarının erken teşhisi için görüntü işleme tabanlı sınıflama problemine yönelik gerçekleştirilmiştir.


Bu bölümde termal görüntülerin elde edilmesi, yenidoğan termal veri setinin organize edilmesi, görüntü ön işleme teknikleri, veri artırma teknikleri, makine öğrenmesi-derin öğrenme yöntemleri ile sınıflanması uygulamalarının ve doğrulama-değerlendirme kriterlerinin detayları verilmiştir.

3.1. Yenidoğan Termal Görüntü Veri Tabanının Oluşturulması

Çalışmada kullanılacak veriler Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesinden alınmıştır. Söz konusu birim 3 öğretim üyesi, 35 yenidoğan hemşiresi (beslenme ve eğitim hemşiresi dahil) ile hizmet vermektedir. Yoğun bakım ünitesinde 36 yatak 3. basamak, 9 yatak 2. basamak olmak üzere toplam 45 yatak kapasitesiyle hasta bakımı yapılabilmektedir. Yıllık ortalama 1000'in üzerinde hasta takip edilmektedir. Yoğun bakım ünitesinde hem aşırı düşük doğum ağırlıklı ileri derecede prematüre bebeklere hem de cerrahi gereksinimi olan term/preterm bebeklere hizmet verilmektedir. Bakım verilen hastaların %60'ı prematüre bebekler olup bu bebeklerde görülebilen respiratuvar distres sendromu, patent duktus arteriyozus, nekrotizan enterekolit, intraventriküler kanama, prematüre retinopatisi ve bronkopulmoner displazi gibi prematürite ile ilişkili hastalıklara müdahale edilmektedir.


Uzman çocuk doktorlarının gözetimi ve yönlendirmesi ile düzenli aralıklarla görüntüleme yapılmıştır. Termal görüntüleme tabanlı yenidoğan görüntüleme çalışmaları için alınan 6 Ocak 2015 tarih ve 2015/16 sayılı etik kurul onay raporu EK-1'de sunulmuştur. Bebeklerin ölçüme hazırlanmasında yenidoğan yoğun bakım ünitesi teknik personeli ve yoğun bakım hemşireleri destek vermiştir. Termal görüntüler Infratec® firması tarafından tasarlanan IRBIS programı ve yaklaşık 80 cm yüksekliğe sabitlenen Variocam HD kızılötesi kamera kullanılarak ortam sıcaklığı 25.5 °C'ye ayarlanan yoğun bakım ortamında kaydedilmiştir. Kullanılan termal kamera, 1,024 × 768 çözünürlükte,

0.01 °C termal hassasiyetle ve -40 ila +2000 °C aralığındaki sıcaklıklarda ölçüm yapabilmektedir. Bebeklerin sıcaklık değerlerinin korunması amacıyla görüntü alma işlemi bir dakika olarak ayarlanmış ve her yenidoğandan bir dakika içerisinde yüz adet termal görüntü elde edilmiştir. Süreç bebeğin baş, gövde ve abdomen bölgelerinden alınan görüntüler için tekrarlanmıştır. Böylece veri toplama süreci boyunca bebeklerden yaklaşık 40,000 adet termal görüntü kaydedilmiştir. Uygulanan ölçüm kurulumu Şekil 3.1’de gösterilmektedir.



Şekil 3.1. Yenidoğan termogramlarının kaydedilmesi için kurulan ölçüm düzeneği, a) termal kamera, b) yenidoğan, c) inkübatör, d) kullanıcı arayüzü

Görüntü alımı süresince kapalı inkübatörlerin uzun süreler boyunca açık tutulması yenidoğan döneminde ani ısı kaybına ve hipotermiye neden olacağı için baş-gövde ve abdomen görüntüleme süreci toplam beş dakika içerisinde tamamlanmaktadır. Uygulamalarda kullanılan termal görüntülerden bazıları Şekil 3.2’de gösterilmektedir.




Şekil 3.2. Elde edilen termogramı örnekleri

Termogramlar taşınabilir bilgisayar ve termal kamera uygulaması kullanılarak üretildikten sonra RGB ve sıcaklık haritası formatlarında kaydedilmiştir. Yenidoğanlardan alınan baş, gövde ve abdomen görüntüleri incelenmiş ve uygulamada kullanılması Çizelge 3.1’de belirtilen gerekçelerle mümkün olmayan görüntüler ve hastalık sınıfları elenerek mevcut veri seti güncellenmiştir. Bu veri azaltma işlemi, tez çalışmamızın odağını oluşturan “sınırlı veri setiyle sınıflama” konseptini desteklemektedir. Veri setinden çıkarılan bazı görüntü örnekleri Şekil 3.3’te verilmiştir.

Çizelge 3.1. Veri setine dahil edilmeyen görüntüler ve dahil edilmeme gerekçesi

Veri setinden çıkarılan veriler	Dahil edilmeme gerekçesi
Gövde görüntüsü bulunmayan yenidoğan verileri	Sınıflama çalışmasında kullanmayı öngördüğümüz görüntüler, hastalık sınıflarının %90’lık bölümünü içeren gövde görüntüleridir. Bu nedenle gövde görüntüsü olmayan bebekler veri setinden çıkarılmıştır.
Mevcut gövde görüntüsü sınıflamaya elverişsiz yenidoğan verileri	Bazı bebeklerin vücutlarında gövde yüzeyinde görece büyük alan kaplayan sargı bezi ve plaster gibi görüntülerde artifakta neden olan materyal bulunmaktadır. Bu bebeklere ait görüntüler veri setinden çıkarılmıştır.
Görüntülemeye ihtiyaç duyulmayan hastalık gruplarındaki yenidoğan verileri	Gelişim geriliği (IUGR), Down sendromu, preeklampatik anne bebeği gibi hastalıklara sahip bebeklere ait görüntüler veri setinden çıkarılmıştır.




Şekil 3.3. Veri setine dahil edilmeyen termogram örnekleri

3.1.1. YYBÜ’nde karşılaşılan olgular

Uzmanlar tarafından verilen hastalık etiketlerine göre veri seti ve sınıflama çalışmasında kullanılacak hastalık sınıfları organize edilmiş; aynı vücut bölgesinde termal değişiklik göstermesi beklenen hastalıklar ile aynı organları etkileyen veya aynı organlardan etkilenen hastalıklar 7 sınıfa indirgenen yeni veri seti içerisinde tanımlanmıştır. Karşılaşılan olgular ve hangi grupta ele alındıkları aşağıda açıklanmıştır.

Şekil 3.4’te YYBÜ’nde gözlem ve tedavi sürecinde bulunan yenidoğanın uzmanların etiketlerine göre değerlendirmeye alındığı olgu grupları ile incelenen hastalık alt grupları verilmiştir.



Şekil 3.4. YYBÜ’nde karşılaşılan olgulara göre veri setinin organize edilmesi

3.1.1.1. Kardiyovasküler hastalıklar

Kardiyovasküler hastalıklar (KrdH) sınıfında patent duktus arteriosus (PDA), hipoplastik sol kalp (HSK), aort koarktasyonu (AK), konjenital kalp hastalığı (KKH), pulmoner hipertansiyon (PH), atriyal septal defekt (ASD), ventriküler septal defekt (VSD) hastalıkları değerlendirilmiştir. Doğumsal kalp anomalisi olarak da bilinen KKH,

kalp ve kalbin büyük damarlarında görülen yapısal bozukluk olarak tanımlanmaktadır (Konak ve ark., 2019). Duktus arteriozusun yaşamın ilk 72 saatinden sonra hala kapanmamış olması durumu PDA olarak tanımlanmaktadır. PDA erken doğmuş bebekler arasında en yaygın kardiyak durumdur (Mosalli ve ark., 2009). Hipoplastik sol kalp sendromu (HSK), kalbin sol tarafının ciddi derecede az gelişmiş olduğu nadir bir doğumsal kalp defektidir (Tchervenkov ve ark., 2006). AK, aortik damarın daralması olarak tanımlanmaktadır, Kan akımı kalpten vücuda gönderilirken dar bir yerden geçmek zorunda kalmaktadır. Bu hastalıkta darlığın bulunduğu yerden kalbe kadar olan bölümdeki kan basıncı yükselir. (Campbell, 1970a). PH, kalbin sağ tarafının pompaladığı kan akımına karşı oluşan basıncın kalbin odacıklarındaki damarları (sağ atriyum ve sağ ventrikül) etkilemesiyle ortaya çıkan yüksek tansiyon türüdür (Alan ve Nalbantgil, 2010). ASD, atriyal septumdaki bozukluk (delik) olarak tanımlanmakta olup sağ atriyumdan sol atriya istenmeyen hava geçişi olarak ortaya çıkar (Campbell, 1970b). VSD ise ventriküller arasında oluşan anormal bir açıklık anlamını taşıırken, oksijence zengin ve oksijence fakir kanın karışmasına neden olur (Spicer ve ark., 2014). Pulmoner arter banding (PAB) akciğere giden kan atımı aşırı olması durumunda akciğer atardamarında kan basıncını düzenleme işlemidir (Nagashima ve ark., 2011).

3.1.1.2. Özofagus atrezisi

Konjenital olarak özofagus ve trakea arasında anormal bir bağlantı olarak tanımlanır ve yaygın olarak trakeo-özofageal fistül ile ortaya çıkar. (van Lennep ve ark., 2019). Özofagus atrezisi (ÖA) doğumsal olarak yemek borusu ve soluk borusu arasında fistül (bağlantı) şeklinde gözlemlenir. Tanı için radyolojik tetkiklere ihtiyaç duyulmakta ancak kontrast maddenin aspirasyon zorluğu nedeniyle risk barındırmaktır (McDuffie ve ark., 2010). Fistül cerrahi işlem ile giderilinceye kadar solunum ile ilgili sorunlar devam etmektedir. Erken teşhis edilmesi hayati öneme sahip olan özofagus atrezisinde cerrahi operasyon gerçekleştirilene kadar çok sıkı gözlem ve bakım gerekmektedir (Sillen ve ark., 1988).

3.1.1.3. Enfeksiyon hastalıkları

Neonatal adenovirüs enfeksiyonu ölümcül bir hastalık olarak kabul edilir. Adenovirüsler, genellikle iyi huylu ancak bazen şiddetli olabilen solunum yolu

hastalıklarına neden olan yaygın pediatrik patojenlerdir (Brandt ve ark., 1969). Pnömoni (zatürre), akciğerdeki hava keseciklerinin iltihaplı bir sıvı ile dolması ile ortaya çıkmaktadır. Yenidoğanda yaygın olarak görülen pnömoni enfeksiyonu; respituar sinsitiyal virüsüdür (RSV). Virüsler, bakteriler ve nadiren mantar enfeksiyonlarının akciğerlere ulaşmasıyla oluşan pnömoni oldukça bulaşıcıdır. Neonatal dönemde en yaygın mortalite nedenlerinden biridir (White ve ark., 1981).

3.1.1.4. İntestinal anomaliler

İntestinal atrezi (İAtr) ve intestinal obstrüksiyon (İO) yenidoğanlarda acil cerrahi tedavi gerektiren birincil konjenital anomalilerdir ve intestinal anomaliler (İA) sınıfında ele alınmışlardır. Atrezi bağırsağın bir bölümünün oluşmaması anlamını taşımaktadır. Bu durumda gıdaların ve bağırsak içeriklerinin boşaltımın uç kısmına ilerlemesi imkansızdır. İnce bağırsak atrezileri doğumsal anomalilerdir ve intestinal tıkanıklıkların en sık nedenidir. Bu hastalıklarda erken cerrahi müdahale ve yeterli bağırsağın korunması hayat kurtarıcıdır. Kusma, abdominal şişlik ve mekonyum problemleri ile görülür. (Dalla Vecchia ve ark., 1998). İntestinal atrezisi olan bebekler için mevcut semptomlar bağırsak tıkanıklığı ile uyumludur. İntestinal obstrüksiyon ise bağırsak içeriğinin gastrointestinal sistem içinde distale doğru olan geçişinin, kısmen ya da tamamen tıkanmasıdır. Yenidoğanda gaz ve gayta çıkaramama, sancı ve karında distansiyon olarak görülür. Çoğu bebek önemli abdominal şişlik göstermez. Bu nedenle teşhis edilmesi için genellikle ultrasonografi, MR ve BT yöntemlerine başvurulmaktadır (Karakoç ve Hamaloğlu, 2006).

3.1.1.5. Nekrotizan enterokolit

Nekrotizan enterokolit (NEC) hastalığı, yaşamın ilk haftalarında görülen bir durumdur ve bağırsak duvarında iltihaptan nekroza (doku ölümü) kadar ciddi sorunlara neden olabilir. Yeni doğan bebeklerde görülen en önemli gastrointestinal acil durumlardan biridir. Bağırsak mukozasının iskemik nekrozu ile karakterizedir. Bu nekroz, iltihaplanma, enterik bakteri istilası ve bağırsak gazının kas dokusu ve portal venöz sisteme geçişi ile ilişkilidir (Neu, 1996). Her 1000 canlı doğumdan 1 ila 3'ünde görülen NEC hastalığı, yenidoğan yoğun bakım ünitelerinde yatışların % 1-7.7'sinin gerekçesidir (Kosloske, 1994). Kısa sürede teşhis ve tedavi edilmezse mortalitesi çok

yüksektir (Caplan ve ark., 2001). Diğer intestinal anomalilerden ayırt edilmesi, tedavi ve cerrahi planlama için kritiktir.

3.1.1.6. Prematürite

Dünyada bölgesel olarak değişmekle birlikte, tüm gebeliklerin yaklaşık %10'u 2500 gram ve altında doğan düşük doğum ağırlıklı bebeklerdir. Prematürite (PRM) olarak nitelendirilen düşük doğum ağırlıklı yenidoğanların %70 ila %75'i prematüre doğumlardır. 37. gebelik haftasından önce bebeğin doğumu olarak tanımlanır (Rondo ve ark., 2003). Prematüre bebekler, organ ve doku sistemleri yeterince gelişmeden doğdukları için, diğer bebeklerle karşılaştırıldıklarında, öğrenme ve davranış bozuklukları, serebral palsy, algı bozukluğu, enfeksiyon ve kronik solunum hastalıkları açısından daha yüksek riskli gruptadırlar (Egbe ve ark., 2015). Prematürite teşhisi, tedavi planlaması açısından önemlidir. Dış görünüşün matürasyon göstergelerine göre prematürelilik derecesi tespiti yapılmaktadır. Örneğin cildin matüritesi keratin tabakasının miktarı ve lanugo adı verilen tüylerin miktarı ile ölçülmektedir. Meme başının görüntüsü ve ayak tabanı çizgilenme durumu gibi tetkikler prematüritenin belirlenmesinde gözlem yeteneğinin önemini vurgulamaktadır.


3.1.1.7. Pulmoner anomaliler

Görüntülenen bebekler arasında en sık görülen pulmoner anomaliler (PA); solunum sıkıntısı sendromu (RDS), geçici taşipne ve pnömotorakstır. Ayrıca, bilinmeyen bir nedeni olan solunum sıkıntısı sendromlu yenidoğanlar bu sınıfa dahil edilir. Bebeğin doğumda aldığı ilk nefesle akciğerler açılır ve içerideki sıvı hava ile değiştirilir. Bu olay genellikle doğumdan sonraki ilk 2-6 saat içinde gerçekleşir. Bazı durumlarda, bu sıvının boşalması gecikir ve akciğerlerde oksijen değişimi sağlanmaz. Bu durumda, bebek ihtiyaç duyduğu tüm oksijeni alamaz ve solunum sıkıntısına girer (Bahadue ve Soll, 2012). RDS'nin ana nedeni terminal hava yollarında yüzey aktif madde eksikliğidir. Sürfaktan eksikliği genellikle sürfaktan bileşenlerinin sentezi için gerekli enzimlerin olgunlaşmamasından ya da sürfaktanı yapan tip II pnömositlerin işlevinin bozulmasından kaynaklanmaktadır. Yeni doğmuş bir bebeğin geçici solunumu olarak da adlandırılan sürece geçici taşipne (TTN) denir ve bu durumda bebekte sık soluma, solunum güçlüğü ve hafif morarma gözlenir (Köksal ve ark., 2002). Yaş akciğer

sendromu olarak da adlandırılan TTN sürecinde bebeğe serum takılarak kuvözde izlenmesi, düşük düzeyde oksijen verilmesi ve akciğer grafisi çekilmesi gerekebilir. Pnömotoraks, solunum sıkıntısı nedenlerinde biri olup acil müdahale gerektiren bir problemdir. Viseral ve paryetal plevra arasında serbest hava birikimi olarak ortaya çıkmaktadır. Yenidoğan döneminde %1-2 oranında görülürken, erkeklerde ilk 3 günde en sık görülür. Yüksek mortalite ve morbiditeye neden olur (Günay ve ark., 2015). Bazı durumlarda asemptomatik seyredebilen pnömotoraks olgularında erken tanı ve tedavi hayat kurtarıcı olmaktadır (Karabel ve ark., 2013).

3.1.2. Termal görüntülemeye deneysel standartlar

Bir yüzey tarafından yayılan kızılötesi radyasyon, nem, hava akışı ve ortam sıcaklığı gibi deneysel koşullara bağlıdır. Bu nedenle termografi deneylerinin, özellikle sıcaklık değişimlerinin birkaç derece içinde olduğu medikal uygulamalarda kontrollü ortamlarda yapılması mutlak bir zorunluluktur. Termografik görüntüleri karşılaştırmak için standart bir protokol izlenmelidir. Yayınlanan çalışmalar medikal uygulamalarda ancak belirli standartlara uyulduğunda güvenilir sonuçlar üretebileceğini ortaya koymuştur (Schwartz ve ark., 2006; Ammer, 2008; Anonymous, 2013a; 2013b). Medikal termografi deneyleri için önerilen ve bu tez çalışmasında uygulanan ölçüm kurulumları Şekil 3.5'te verilmiştir. Deney ortamının sıcaklığı ve nemi belirli sınırlar içinde tutulmalı ve ölçümde geometrik hataları en aza indirmek için kamera, gözlem yüzeyine dik olarak yerleştirilmelidir.



Şekil 3.5. Termal görüntülemeye ölçüm kurulumu örnekleri, a) yetişkin ölçüm düzeneği, b) önerilen yenidoğan ölçüm düzeneği

Termografi deneyleri sırasında denekler rahat bir ortamda tutulmalıdır. Bir termografik inceleme sırasında, hastaların görüntülenecek vücut bölümü, vazokonstriksiyonun cildin soğumasına neden olduğu ve altta yatan anormalliklerden kaynaklanan sıcak noktaların açıkça görünür hale getirildiği hafif bir termal stres üretmek için soğutulabilir (Jones, 1998). Amalu ve ark. muayene odasının sıcaklık ve neminin, deneklerin fizyolojisinin "titreme veya terleme durumuna" girmeyecek şekilde kontrol edilmesi gerektiğini, akkor lamba veya direkt güneş ışığı gibi ikincil kızılötesi kaynaklardan arınmış olması gerektiğini bildirmiştir (Amalu ve ark., 2006). Deneklerin doğrudan güneş ışığına maruz kalmamaları ve termografi incelemelerinden hemen önce kozmetik, terlemeyi önleyici veya deodorant kullanmamaları önerilir. Deneklerin termal dengeye ulaşması için bir termal alışma süresi gerekmektedir (Lahiri ve ark., 2012).


Yenidoğan termogramları kaydedilirken termal kamera yüksekliği (80-100 cm) ve açısı (90 derece) standartlara uygun şekilde ayarlanmıştır. YYBÜ ortam sıcaklığının uygunluğu gözetilmiş ve 45-60 saniye alışma süresi akabinde ölçüm gerçekleştirilmiştir. Tüm vücut yüzeyinden ölçüm alındığı için lokal soğutma gereksinimi bulunmamaktadır. Kameranın titreşimden kaynaklanan artifaktları minimize etmek için sabit üç ayak kullanılmıştır.

3.1.3. Termogramların kaydedilme biçimleri

Termogramlar elde edildikten sonra sıcaklık haritaları ve RGB görüntüler olarak kaydedilip kullanılabilir. Sıcaklık haritası, direkt olarak sıcaklık değerlerinin bulunduğu iki boyutlu matrise verilen isimdir. Bu matrislerin görselleştirilmesiyle gri-seviye termal görüntüler ortaya çıkar. RGB ise görüntülerin sıcaklık değerlerine göre alt ve üst eşik değerleri belirlenmesiyle elde edilen renkli görüntüleri temsil etmektedir.

Sıcaklık haritası görüntülerinde yenidoğanın termal kameralar aracılığıyla tespit edilen cilt sıcaklık değerlerinin minimum sıcaklık 0, maksimum sıcaklık 255 değerine eşit olacak şekilde normalize edilmesiyle gri-seviye olarak görselleştirilir. RGB görüntüler, sıcaklık değerlerinden yola çıkılarak atanan eşik değerlerine göre belirli renk aralıkları için elde edilmektedir. RGB görüntü oluştururken, minimum eşik değeri minimum sıcaklık değerinden küçük, maksimum eşik değeri maksimum sıcaklık değerinden büyük olarak seçilmelidir. Aksi takdirde eşik değerleri dışında kalan alanlarda siyah bölgeler oluşacak ve bilgi kaybına neden olacaktır.

Şekil 3.6’da RGB ve sıcaklık haritası formatlarında kaydedilmiş örnek termogramlar gösterilmiştir. Şekil 3.6 (a)’da verilen RGB görüntü için alt eşik değeri 28 °C, üst eşik değeri ise 40 °C olarak belirlenmiştir.




Şekil 3.6. RGB görüntüler ve sıcaklık haritalarının karşılaştırılması (a) 28-40 °C aralığında RGB görüntü (b) sıcaklık haritası (Ornek ve ark., 2018)

Şekil 3.6’da 1 ve 2 ile numaralandırılmış çerçeveler içinde kalan alanlar, 3 numaralı çerçeve içindeki alanlara göre daha sıcaktır. RGB formatında sıcak alanlar kırmızıdan mor tonlarına, soğuk alanlar ise maviden siyaha yakınsanmaktadır. Gri-seviye sıcaklık haritalarında ise sıcak bölgeler beyaza, soğuk bölgeler ise siyaha yakınsanır (Ornek ve ark., 2018).


3.1.4. Görüntü ön işleme

Yenidoğan termal ölçümlerinin gerçekleştirilmesi sırasında bebeklerin konfor ortamının bozulmaması için farklı uygulamalar yapılmıştır. Bu bağlamda bazı yenidoğan termogramları sahne pozisyonunda (Şekil 3.7a), bazıları portre pozisyonunda (Şekil 3.7b) kaydedilmiştir. Ayrıca termogramlarda, yenidoğan vücudu dışında kalan alanlar bulunmaktadır. Sınıflama uygulamalarına girdi olarak verilecek görüntülerin standartlaştırılması için görüntü ön işleme tekniklerine ihtiyaç duyulmuştur.



Şekil 3.7. Farklı kamera doğrultuları ile kaydedilmiş yenidoğan termogramları a) sahne çekim yenidoğan termogramı, b) portre çekim yenidoğan termogramı

Şekil 3.8’de uygulamalarda kullanılan görüntü ön işleme süreci gösterilmektedir. Sahne çekimde yenidoğan kameranın kaydettiği görüntüye göre dikey sırt üstü, portre çekimde ise yatay sırt üstü pozisyonda görülmektedir.



Şekil 3.8. Önerilen görüntü ön işleme prosesi

Her iki çekim uygulamasının yapay zekâ tekniklerinin kullanımına uygun hale getirilmesi için portre çekim görüntülerde 90° saat yönünde döndürme işlemi yapılmıştır. Ayrıca yenidoğan gövdesi dışında kalan alanların bozucu etki yapmaması ve standartlaşması amacıyla alt, üst ve her iki yandan kırpma operasyonları gerçekleştirilmiştir. Kırpma yapılırken görüntü boyutlarının tüm termogramlar için aynı olmasını sağlamak amacıyla kare formatta (700 x 700) olmasına dikkat edilmiştir. Son olarak görüntüler yeniden boyutlandırma yapılarak 400 x 400, 105 x 105 gibi farklı

boyutlarda elde edilmiştir. Uygulamalarda gri-seviye veya RGB formatlarında görüntülerin kullanılabilmesi için her iki renk uzayında veri tabanına kaydedilmiştir.

3.2. Yapay Zekâ ve Derin Öğrenme Yaklaşımları

Yapay zekâ kavramı, makinelere insanlar gibi düşünme, karar verme, karşılaştırma, analiz etme gibi birtakım fonksiyonların kazandırılmasıdır. Makinelerin belirli insan davranışlarını modelleyerek veri hesaplama, kontrol sistemlerini yönetme, tıbbi teşhis gibi belirli bir uzmanlık alanı ile ilgili beşeri düşünme sürecinin benzeşimini yapma gibi becerilere sahip olması mümkündür (Nilsson, 2014). Yapay zekâ modelleri, biyolojik sinir ağlarını andıran modellerde düzenlenmiş birçok doğrusal olmayan hesaplama ögesinden oluşur. Bilgisayar teknolojisinde yaşanan gelişmelerin sağladığı daha düşük maliyetli-yüksek işlem kapasitesine sahip bilgisayarlar ve veri toplama süreçlerinin kolaylaşmış olması sayesinde yapay zekâ alanında büyük ölçekli araştırma yapabilmek ekonomik açıdan mümkün hale gelmiştir.


Son yıllarda, araştırmacılar tarafından yapay zekâ tabanlı sınıflayıcıların biyomedikal çalışmalara yönelik, ön-tanı, cerrahi planlama, operasyonel gözlem ve takip gibi süreçlerde sağlık personeline destek veren uygulamaları geliştirilmiştir. Yapay zekâ yöntemlerini, makine öğrenmesi ve derin öğrenme algoritmaları başlıkları altında incelemek mümkündür. Medikal sınıflama problemlerinde yaygın olarak kullanılan makine öğrenmesi algoritmalarından bazıları; yapay sinir ağları (McCulloch ve Pitts, 1943), destek vektör makinesi (Cortes ve Vapnik, 1995), naive bayes (NB) (McCallum ve Nigam, 1998), k-en yakın komşu (k-NN) (Altman, 1992), lojistik regresyon (LR) (Walker ve Duncan, 1967), karar ağaçları (KA) (Morgan ve Sonquist, 1963), rastgele orman (RO) (Ho, 1998) olarak karşımıza çıkmaktadır. Derin öğrenme, öğrenme işleminin gerçekleşmesi için çoklu katmanlardan meydana gelen ve özellik çıkarma, özellik seçme işlemlerini kendi kendine yapabilen modellerin oluşturulmasıdır (Krizhevsky ve ark., 2012). Yapay sinir ağlarının daha fazla sayıda katman ve nöron içeren versiyonu bir derin öğrenme modelidir ve çok katmanlı algılayıcı olarak tanımlanmaktadır. Çok katmanlı algılayıcılar (Lippmann, 1989), evrişimli sinir ağları (LeCun ve ark., 1998), otomatik kodlayıcılar (Kramer, 1991) ve Siyam sinir ağları (Bromley ve ark., 1993) gibi derin öğrenme modelleri bulunmaktadır. Bu yöntemler görüntü sınıflama, konuşma tanıma, görsel veri tanıma, nesne tanıma gibi birçok alanda başarı kriterini yükseltmiştir. Tez

çalışmaları kapsamında, termal görüntülerin sınıflanmasında yapay sinir ağları, destek vektör makinesi, evrişimli sinir ağları ve Siyam sinir ağları kullanılmıştır.

3.2.1. Yapay sinir ağları

Yapay Sinir Ağları, 1943'te McCulloch ve Pitts tarafından geliştirilen ve biyolojik sinir sisteminden ilham alınarak oluşturulmuş, biyolojik sinir ağlarının yapı ve işlevlerine dayanan bir hesaplama modelidir (McCulloch ve Pitts, 1943). Çok karmaşık sistemleri veya değişkenler arasındaki ilişkinin bilinmediği yüksek dereceli doğrusal olmayan sistemleri modelleyebilir. Örüntü tanıma, sınıflama, modelleme ve çok değişkenli veri analizi gibi birçok uygulamada kullanılmaktadır. YSA paralel olarak çalışabilen temel işlem birimlerinden (düğümler veya nöronlardan) oluşmaktadır. Sinir ağındaki nöronlar bağlantılar ile bağlanır ve her bir bağlantı onunla ilişkili bir sayısal ağırlığa sahiptir. Her nöron, bağlantılarıyla giriş sinyallerini alır ve tek bir çıkış sinyali üretir.


Şekil 3.9'da YSA ve biyolojik sinir ağlarının benzer nöron yapıları gösterilmiştir.



Şekil 3.9. Biyolojik sinir ağları ve YSA'nın yapısal benzerlikleri, a) biyolojik sinir hücresi, b) temel düzeyde nöron örneği

Biyolojik sinir sistemindeki nöronlar yapay sinir ağı mimarisinde işlem birimleri olarak ifade edilirken, dentritler toplama fonksiyonuna, hücre gövdesi aktivasyon fonksiyonuna, sinapslar ağırlıklara, eşik değerler bias değerlerine, aksonlar ise çıkış değerine benzetilebilir.

YSA yapısında tipik olarak giriş katmanı, gizli katmanlar ve çıkış katmanı bulunmaktadır (Şekil 3.10).




Şekil 3.10. Çok katmanlı ileri beslemeli sinir ağı yapısı

Yapay sinir ağlarında nöronlar, bağlantılarla birbirine bağlanır. Her bir bağlantı, girdisinin gücü ile ilişkili bir sayısal ağırlık değerine sahiptir. Her bir nöron, bağlantılarıyla giriş sinyallerini alır ve tek bir çıkış sinyali üretir. Çıkış sinyalini üretmek için önce nöronlar giriş sinyallerinin ağırlıklı toplamını hesaplar ve bir net girdi değeri belirler. Daha sonra net girdiye bir aktivasyon fonksiyonu uygulanarak çıkış sinyali üretilir. Aktivasyon fonksiyonları, bir nöronun çıkışını istenen değer aralığına (aktivasyon fonksiyonun türüne göre değişir) sınırlamaktır. Pratikte sınıflanması istenen veri öncelikle giriş katmanına beslenir. Burada sınıflanacak verinin özellik sayısı ile giriş katmanında bulunan nöron sayısına eşittir. Giriş katmanının ardından özellikler gizli katmana geçerek ağırlık değerleri elde edilir. Gizli katmandan geçen özellikler en son çıkış katmanına aktarılır. Burada istenilen sınıfın sayısal değeri ile elde edilen değer arasındaki fark hesaplanır ve ağırlıklar geri yayılım ile güncellenir (Ceylan, 2004). YSA'nın ağırlık güncelleme işlemi optimum sınıflama başarımı elde edilene kadar devam etmektedir.

3.2.2. Destek vektör makinesi

DVM, sınıflama veya regresyon problemleri için en yaygın kullanılan, denetimli makine öğrenmesi algoritmalarından biridir. Temelde bir optimum hiper-düzlem oluşturarak sınıflar arasındaki maksimum aralığı (marjin) elde ederek ikili sınıflama problemlerini gerçekleştirmektedir (Cortes ve Vapnik, 1995). DVM algoritması, her bir veri özellik değeri ile n-boyutlu boşluğa (n: özellik sayısı) bir nokta olarak çizilir. Ardından, iki sınıftan oldukça iyi ayrım yapan hiper-düzlemi bularak sınıflama gerçekleştirilir.

Şekil 3.11’de genel bir DVM yapısı gösterilmiştir.



Şekil 3.11. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi

Şekil 3.11’de verilen örnek DVM için hiper-düzlemin belirlenmesi işleminde iki sınıfa ayıran yeşil bölgeye marjin adı verilir. Maksimum marjinin (ρ) elde edilmesi için Eşitlik 3.1 kullanılmaktadır.

$$\rho = \frac{2}{\|\vec{w}\|} \quad (3.1)$$

Burada $\vec{w}$ çoklu düzlemin normali (ağırlık vektörü) değeri olarak, $\|\vec{w}\|$ ise $\vec{w}$ ’nın Öklid formu şeklinde ifade edilmektedir. $\vec{x}$, girdi vektörü, b ise sapma değeri olarak adlandırılmaktadır.

Hiper düzlem belirlenirken, doğrusal (do), polinomik (po) ve radyal çekirdek fonksiyonları kullanılabilir. Eşitlik 3.2, Eşitlik 3.3 ve Eşitlik 3.4'te çekirdek fonksiyonlarının nasıl hesaplandığı gösterilmiştir.

$$do(X, Y) = (X \bullet Y) \quad (3.2)$$

$$po(X, Y) = (\gamma \times (X \bullet Y) + C)^d \quad (3.3)$$

$$rad(X, Y) = -\gamma \times ||X - Y||^d \quad (3.4)$$


Eşitliklerde verilen;

X ve Y , n boyutlu girdileri, $X \bullet Y$, X ve Y için iç çarpımı, $||X - Y||$, X ve Y arasındaki mesafeyi, C kayma parametresini, d polinomun derecesini, γ ise fonksiyonun ayarlanabilir parametresini ifade etmektedir.

3.2.3. Evrişimli sinir ağları

Evrişimli sinir ağları (ESA), yüksek görüntü performansı sağlayan ve nesne algılama, görüntü tanıma, görüntü bölütleme ve sınıflama gibi uygulamalara dayanan derin öğrenme modelidir. Son yıllarda ortaya atılan ve derin öğrenme algoritmalarından biri olan ESA ile görüntüler üzerinde yapılan nesne tanıma, sınıflama, gürültü giderme, görüntü artırma ve bölütleme gibi işlemler yüksek özgüllük ve duyarlılık oranları ile gerçekleştirilmektedir. ESA konvolüsyon, aktivasyon fonksiyonu, havuzlama ve tam bağlı katman gibi katmanlardan meydana gelmektedir. Birbirini takip eden konvolüsyon katmanları görüntüde bulunan kenar, köşe ve eğrilik gibi düşük seviyeli özelliklerden doku gibi yüksek seviyeli özelliklere doğru özelliklerin elde edilmesini sağlar. Yapısında evrişim ve tam bağlı ağ olmak üzere iki ana katman barındırır. Evrişim katmanındaki konvolüsyon adımları seçilen kernel boyutuna bağlı olarak özellik çıkarma gerçekleştirir. Kullanılan kernel boyutları deneysel olarak 3×3 , 5×5 veya 7×7 olarak seçilebilir. Havuzlama işlemi, havuzlama boyutu ve ortalama veya maksimum havuzlama gibi tekniklere göre elde edilen özellik haritasının boyutundaki azalmayı ifade eder, özellik seçimi havuzlama işlemi tarafından yapılır (Ornek ve ark., 2019). Tam bağlı ağ katmanı

ise düzleştirme ve ağ katmanları olmak üzere iki parçadan meydana gelir. Düzleştirme katmanında elde edilen özellik matrisi özellik vektörü haline getirilir. Ağ katmanı genellikle yapay sinir ağlarının tercih edildiği ve girişteki objenin hangi kategoriye ait olduğu sonucunun elde edildiği katmandır. Şekil 3.12’de iki konvolüsyon, iki havuzlama, bir düzleştirme, iki ağ katmanı bulunan tipik bir ESA mimarisi örneği verilmiştir.




Şekil 3.12. İki konvolüsyon, iki havuzlama, bir düzleştirme, iki ağ katmanı bulunan örnek ESA mimarisi

3.2.3.1. Konvolüsyon işlemi

Konvolüsyon katmanı giriş görüntüsünü belirlenen boyutlardaki kerneller ile klasik konvolüsyon işlemine tabi tutarak n katmanlı matrisler oluşturmaktadır. Oluşturulan bu matrislere özellik haritaları ismi verilir. Konvolüsyon katmanındaki özellik haritaları, Eşitlik 3.5 ile elde edilmektedir.

$$I_i^l = f(\sum_j I_i^{l-1} \otimes w_{ij}^l + b_i^l) \quad (3.5)$$

Eşitlik 3.5’te verilen I_i^l ifadesi çıkış matrisini, w_{ij}^l özellik matrisini, b bias değerini, f ise aktivasyon fonksiyonunu ifade etmektedir. Konvolüsyon katmanının girişindeki görüntü matrisi üzerinde 3 x 3, 5 x 5 gibi kare matris formunda filtreler matrisin ilk elemanından başlamak üzere gezdirilir. Seçilen filtre son elemana kadar uygulanır ve özellik matrisleri oluşturulur (Krizhevsky ve ark., 2012). Şekil 3.13’te örnek bir konvolüsyon işlemi gösterilmiştir.



Şekil 3.13. Örnek konvolüsyon işlemi

Konvolüsyon işleminin matematiksel gösterimi aşağıdaki gibidir:

$$f(x, y) * h(x, y) = \sum_{n1=-\infty}^{\infty} \sum_{n2=-\infty}^{\infty} f(n1, n2) xh(x - n1, y - n2) \quad (3.6)$$


Eşitlik 3.6 uygulanırken, girişteki görüntü matrisinin seçilen filtre boyutundaki ilk parçasının her bir elemanının değeri ile filtrenin karşılık gelen elemanı çarpılarak sonuçlar toplanır. Böylece elde edilen değer, özellik haritasının ilk elemanı olarak yerine yazılır. Bu işleme konvolüsyon adı verilir. Daha sonra belirli bir kaydırma (İng., stride) parametresine bağlı olarak giriş matrisinin ikinci parçası için aynı filtre ile konvolüsyon işlemine tabi tutulur ve özellik matrisinin ikinci elemanı elde edilir. Şekil 3.13'te verilen örnek için aşağıdaki özellik matrisinin ilk elemanının değeri; $(1 \times 1) + (1 \times 2) + (5 \times 1) + (1 \times -1) + (2 \times 4) + (5 \times -1) + (1 \times 1) + (3 \times 2) + (5 \times 1)$ işlemi yapılarak 22 olarak bulunur. Benzer şekilde kaydırma parametresine bağlı olarak çıkış (özellik) matrisinin tüm elemanları oluşturulur.

Çıkışta üretilen özellik matrisinin boyutu Eşitlik 3.7 kullanılarak hesaplanabilir.

$$n_{\zeta} = \frac{n_{giriş} + 2e_k - f_i}{k} + 1 \quad (3.7)$$

Burada $n_{giriş}$ giriş görüntüsünün matris boyutunu, e_k dolgu ekleme (İng., padding) parametresini, f_i filtrenin boyutunu, k filtenin her kaydırma parametresinin değerini ve n_{ϕ} ise üretilen özellik matrisinin boyutunu ifade etmektedir.


Kaydırma parametresi (k) konvolüsyon filtresinin, giriş matrisi üzerinde kaç birim kaydırılacağını ifade eder. Şekil 3.14'te kaydırma işleminde kullanılan k değerinin farklı varyasyonları için örnek özellik matrisi gösterimleri verilmiştir.



Şekil 3.14. k değeri 1 ve 2 iken oluşan aktivasyon haritaları temsili (a) k değeri 1 iken oluşan ilk eleman temsili (b) k değeri 1 iken oluşan ikinci eleman temsili (c) k değeri 2 iken oluşan ilk eleman temsili (d) k değeri 2 iken oluşan ikinci eleman temsili.

Konvolüsyon işlemi yapıldıktan sonra özellik matrisinin boyutu giriş matrisine göre azalmakta ve veri kaybı ortaya çıkmaktadır. Veri kaybını en aza indirmek için dolgu ekleme işlemi gerçekleştirilir. Dolgu büyüklüğü genellikle filtre boyutuna göre belirlenir. Örneğin, filtre boyutu 3 x 3 ise bir piksel, 5 x 5 ise, iki piksel dolgu gerçekleştirilebilir. Dolgu elemanları sıfır olarak veya kenar pikselliyle aynı değerlerde seçilebilir.

Şekil 3.15'te 3 x 3'lük konvolüsyon filtresi uygulanan 6 x 6 boyutundaki giriş matrisine sıfır ekleme işlemi sonucunda elde edilen özellik matrisinin boyutunun yine 6 x 6 boyutlarında olduğu gösterilmiştir.




Şekil 3.15. Sıfır ekleme işleminden sonra uygulanan konvolüsyon filtresine bağlı olarak özellik matrisinin üretilmesi.

3.2.3.2. Havuzlama işlemi

Havuzlama (İng., pooling) katmanı, ağdaki parametrelerin ve hesaplamaların sayısını azaltmak için konvolüsyon katmanının çıktısının boyutunu küçültmek amacıyla kullanılır. Aşırı uyumu kontrol eder. Yaygın olarak iki konvolüsyon katmanı veya tam bağlı katmanlar arasında kullanılan havuzlama katmanında, maksimum-havuzlama ve ortalama-havuzlama gibi yöntemler mevcuttur. Havuzlama işlemi yapılırken, 2 x 2, 3 x 3 gibi boş bir kare çerçeve giriş matrisinin üzerinde, seçilen çerçeve boyutu ile aynı boyuttaki ilk parçadan itibaren, son parçaya kadar dolaştırılır. Havuzlama çerçevesi, üzerine geldiği parçanın ortalama veya maksimum değerini çıkış matrisine iletir. Konvolüsyon işleminde olduğu gibi, bir kaydırma parametresi çerçevenin her adımda kaç birim ilerleyeceğini belirler.

4 x 4 boyutundaki giriş matrisine 2 x 2 boyutundaki havuzlama çerçevesi her adımda 2 birim (k=2) hareket ettirilerek uygulandığında elde edilen çıkış matrisleri Şekil 3.16'da verilmiştir.



Şekil 3.16. Örnek maksimum-havuzlama ve ortalama-havuzlama işlemleri

3.2.3.3. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları çok katmanlı ağlarda doğrusal ifadeleri doğrusal olmayan ifadelerle dönüştürmek amacıyla kullanılır. Temel olarak basit bir sinir ağına girdi (x) değerleriyle, ağırlıklar (w) çarpıldıktan sonra bias (b) değeri eklenerek çıkışa aktarılmaktadır. Eğer aktivasyon fonksiyonu uygulanmazsa çıkış sinyali basit bir doğrusal fonksiyon olur. Doğrusal fonksiyonlar yalnızca tek dereceli polinomlardır. Aktivasyon fonksiyonu kullanılmayan sinir ağı sınırlı öğrenme yeteneğine sahip bir doğrusal bağlantı gibi davranacaktır. Ancak sinir ağının, görüntü, video, yazı ve ses gibi karmaşık doğrusal olmayan verileri öğrenmesi gerekmektedir. Derecesi 1'den büyük olan fonksiyonlara doğrusal olmayan fonksiyonlar adı verilir. Aktivasyon fonksiyonları da doğrusal olmayan fonksiyon sınıfına girmektedir. Doğrusal olmayan aktivasyon fonksiyonları sayesinde ağların daha güçlü öğrenmesi sağlanabilir.

Step fonksiyonu, doğrusal fonksiyon, sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu, ReLU, ve softmax aktivasyon fonksiyonları için örnek olarak verilebilir. Çizelge 3.2'de yaygın olarak kullanılan aktivasyon fonksiyonlarının özelliklerinden kısaca bahsedilmiştir. Aktivasyon fonksiyonlarının hesaplanmasına ilişkin eşitlikler aşağıda verilmiştir.

Step fonksiyonu:

$$\hat{y} = \begin{cases} 1 & \text{eğer } wx + b \geq 0 \\ 0 & \text{eğer } wx + b < 0 \end{cases} \quad (3.8)$$

Hiperbolik tanjant fonksiyonu:

$$f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} \quad (3.9)$$

ReLU fonksiyonu:

$$f(x) = \begin{cases} x & \text{eğer } x \geq 0 \\ 0 & \text{eğer } x < 0 \end{cases} \quad (3.10)$$






Softmax fonksiyonu:

$$f(x_i) = \frac{e^{x_i}}{\sum_i^k e^{x_i}}, i = 0, 1, 2, \dots, k \quad (3.11)$$

Sigmoid fonksiyonu:

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.12)$$


Çizelge 3.2. Yaygın olarak kullanılan aktivasyon fonksiyonları ve grafiksel gösterimi

Aktivasyon Fonksiyonu	Açıklama	Grafik
Step Fonksiyonu (Eşitlik 3.8)	Eşik değeri ile ikili sınıflama yapar.	
Hiperbolik Tanjant Fonksiyonu (Eşitlik 3.9)	$[-1,1]$ aralığında çıktı veren doğrusal olmayan bir fonksiyondur.	
ReLU Fonksiyonu (Eşitlik 3.10)	Negatif girdiler için 0 değerini, x pozitif girdileri için x değerini üretir. $[0, +\infty)$	
Softmax Fonksiyonu (Eşitlik 3.11)	Verilen her bir girdinin sınıflardan birine ait olma olasılığını gösteren $[0, 1]$ arası çıktıları üretir.	
Sigmoid Fonksiyonu (Eşitlik 3.12)	Girdi değerinin her biri için 0-1 arasında değer üretir. İkili sınıflama problemleri için kullanılır.	

3.2.3.4. Düzleştirme işlemi

Sınıflama işleminin gerçekleştirilmesi için evrişim katmanının çıkışında elde edilen iki boyutlu özellik matrislerinin tek boyutlu vektöre çevrilmesi gerekmektedir. Matris formundan vektör formuna çevirme işlemi düzleştirme olarak adlandırılır.

Örnek bir 3 x 3 boyutlu matris için düzleştirme katmanında gerçekleştirilen işlem ve elde edilen 9 x 1 boyutundaki vektör Şekil 3.17’de gösterilmiştir.



Şekil 3.17. Düzleştirme işlemi, a) 3 x 3 boyutunda örnek matris, b) verilen matrisin düzleştirilmesi ile elde edilen vektör

3.2.3.5. Tam bağlı ağ katmanı

Tam bağlı ağ katmanı, evrişim katmanında, görüntüden özellik çıkarma, özellik seçme, modeli doğrusal olmayan hale getirme gibi işlemler gerçekleştirildikten sonra elde edilen özellik matrislerinin sınıflanmasını gerçekleştiren katmandır. Tam bağlı ağ katmanının girişi düzleştirilmiş özellik vektörüdür. Bu özellik vektörü, YSA ve DVM gibi makine öğrenmesi yöntemleri ile sınıflanır. Veri boyutunun azaltılması için belli bir eşik değerinin altında kalan özellikler seyreltme (İng., drop-out) işlemi ile elimine edilir. Seyreltme ağı bazı özellikleri ezberlemesini engellemek için önceden belirlenmiş ağıdaki bazı nöronları kaldırma işlemidir, Böylece aşırı uydurma (İng., over fitting) problemi önlenmiş olur.

Tam bağılı ağ katmanı sonucunda üretilen sonuçlara göre ağın geri yayılım algoritması ile eğitimi başlatılmış olur. İlk iterasyonda modelde bulunan ağırlıkların rastgele atanması nedeniyle hata değeri çok yüksek olur. Geri yayılım ile hata değerinin azaltılması ve modelin başarımının yükseltilmesi amaçlanır. İleri yayılım, hata hesaplama, geri yayılım ve ağırlık güncelleme işlemleri tekraren uygulanmaktadır. İleri yayılımda giriş görüntüsü konvolüsyon, havuzlama, aktivasyon, sınıflama adımları gerçekleştirilir ve bir hata fonksiyonu üretilir. Hata fonksiyonu (H) Eşitlik 3.13'te gösterildiği gibi hedeflenen çıkış ile üretilen çıkış arasında farkın n tane örnek için ortalaması alınarak hesaplanmaktadır.

$$H = \frac{1}{n} \sum_{i=1}^n (\text{hedef} - \text{üretilen})^2 \quad (3.13)$$

Hata değeri yüksek bir noktadan sıfır noktasına doğru azaltılması için hatanın ağırlığa göre türevinin alınması gerekmektedir. Geri yayılım boyunca ağırlıklar ile hata değeri arasında türev hesabı yapılarak ağırlık güncelleme (Eşitlik 3.14) işlemi gerçekleştirilmektedir.

$$\omega = \omega_i - \eta \cdot \frac{dH}{d\omega} \quad (3.14)$$

Burada ω_i mevcut ağırlık, η öğrenme oranı, H hata ve ω yeni ağırlık değerini ifade etmektedir.

3.2.3.6. Hiperparametre seçimi

ESA modelleri oluşturulurken, eğitim sürecini yönlendiren bazı değişkenler hiperparametre olarak adlandırılır. Hiperparametreler, eğitim algoritmasının davranışını doğrudan kontrol etmekte ve eğitilen modelin performansı üzerinde etkili olmaktadır. Uygun hiperparametre seçimi, mimarilerinin başarısında önemli bir rol oynar. Öğrenme oranı, momentum, optimizasyon algoritmaları, küme boyutu seçimi ve epok sayısı modelin başarımını etkileyen en önemli hiperparametreler olarak karşımıza çıkmaktadır.

3.2.3.6.1 Öğrenme oranı

Ağırlıkların güncellenmesi için geri yayılım işlemi gerçekleştirilirken türev alınarak hata hesaplanması ve öğrenme oranı ile çarpılması gerekmektedir. Öğrenme oranı sabit seçilebildiği gibi artan-azalan şekilde momentum değerine bağlı olarak belirlenebilir ya da adaptif algoritmalar tarafından öğrenme esnasında değiştirilebilir. Genellikle 0.1 ile 0.000001 arasında öğrenme oranı değerleri tercih edilmektedir. Öğrenme oranının yüksek olması fonksiyonun yerel minimumu atlayarak uzaklaşmasına, düşük olması ise eğitimin uzun sürmesine neden olmaktadır.

3.2.3.6.2 Momentum

Ağın öğrenme sürecindeki salınımları normalize etmek için momentum katsayısı kullanılmaktadır. Bu teknikte, her iterasyonda yeni üretilen değeri olduğu gibi kullanmak yerine, bir önceki değeri momentum katsayısı oranında hesaplama dahil ederek salınımların önlenmesine yardımcı olur.

3.2.3.6.3 Optimizasyon algoritmaları

Yapay zekâ algoritmaları için optimizasyon kavramı, sinir ağlarının ürettiği çıkış ile gerçek değer arasındaki farkı minimum yapma yani hata fonksiyonunun çıktısını sıfıra yakınlaştırma anlamını taşır. ESA gibi derin öğrenme uygulamalarında, maliyet fonksiyonunun mutlak minimum değerine ulaşmak için optimizasyon yöntemleri geliştirilmiştir. Yapay sinir ağlarının optimizasyonu için en çok kullanılan yöntemlerden biri stokastik gradyan inişidir.

Derin öğrenme uygulamalarında yaygın olarak stokastik gradyan iniş algoritması ile geliştirilmiş olan, adam, adagrad, adadelta gibi optimizasyon algoritmaları kullanılmaktadır. Optimizasyon tekniklerinin seçimi modelin tipine göre farklı başarımlar ve hız etkinliği sağlar.

3.2.3.6.4 Küme boyutu

Öğrenmenin her iterasyonunda geri yayılım işlemi ile ağ üzerinde geriye dönük olarak gradyan hesaplaması yapılmakta ve ağırlık değerleri bu şekilde güncellenmektedir.

Bu nedenle ESA uygulamalarında, tüm veri setini anda işleyerek eğitme, zaman ve bellek açısından maliyetlidir. Bu problemi çözmek için; veri seti küçük gruplara ayrılarak eğitim bu küçük gruplar üzerinde yapılmaktadır. Bu şekilde birden fazla girdinin parçalar halinde işlenmesi “küme boyutu seçimi” olarak adlandırılmaktadır. Model tasarlanırken küme boyutu parametresi olarak belirlenen değer; modelin aynı anda ne kadar veriyi kullanacağını tanımlar.

3.2.3.6.5 Epok sayısı

Modelin eğitimi sırasında seçilen küme boyutuna bağlı olarak öncelikle ilk parça eğitilir ve modelin başarımı test edilir. Daha sonra yeni eğitim parçası ile model tekrar eğitilip ağırlıklar güncellenir. Bu işlem her bir eğitim adımında tekrarlanarak model için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine epok sayısı adı verilmektedir. Bu nedenle epok sayısı arttıkça başarımlar da artacaktır. Ancak epok sayısı belli bir değere ulaştıktan sonra başarımın artış ivmesi azalacak ve sıfıra yakınsanacaktır.

3.2.4. Siyam sinir ağları

Yapay sinir ağları, evrişimli sinir ağları gibi sınıflama yöntemlerinde, girdi görüntüsü bir dizi sinir ağı katmanına verilmekte ve son katmanda tüm sınıflar üzerinde bir olasılık dağılımı oluşturulmaktadır. Örneğin, bir görüntüyü kedi, köpek, at ya da zebra olarak sınıflamaya çalışıyorsak eğitim sürecinde, sınıfın her biri için çok sayıda görüntüye ihtiyaç vardır. Sinir ağı yalnızca yukarıdaki 4 görüntü sınıfında eğitildiyse, başka bir sınıfta, örneğin “fil” üzerinde test edilmesi beklenemez. Modelin fil görüntülerini de sınıflanmasını istenirse, çok sayıda fil görüntüsü veri setine eklenerek modelin tekrar eğitilmesi gerekmektedir. Her bir sınıf için yeterli verinin bulunmadığı veya test örneklerinin dinamik olarak değiştiği uygulamalar için geleneksel sınıflama teknikleri işlem ve veri toplama maliyetleri nedeniyle yetersiz kalmaktadır (Fei-Fei ve ark., 2006).


Benzerlik, bilgisayar bilimi ve istatistikte her zaman önemli bir unsur olmuştur. İki element vektörü her karşılaştırıldığında, karşılaştırmanın nihai amacına (Öklid mesafesi, Pearson korelasyon katsayısı vb.) bağlı olarak birçok farklı benzerlik yaklaşımı kullanılabilir (Chicco, 2021).

Derin öğrenme modelleri, genellikle sınıf başına binlerce etiketli örneğe ihtiyaç duymaktadır. İnsanların bebeklikten itibaren çok sayıda örneğe ihtiyaç duymadan birçok kavramı öğrenebileceği iddia edilebilir. Tek-atış öğrenme konsepti insanların öğrenme yeteneğinden yola çıkılarak ortaya atılmıştır. İnsanların az veriden öğrenebilme yeteneği, bir veya birkaç örnekten öğrenebilen modeller üretme motivasyonunu tetiklemiştir. 90'lı yıllarda Bromley ve LeCun tarafından imza doğrulama problemine yönelik olarak ortaya atılan Siyam sinir ağları (SSA) her biri bir giriş vektörünün gizli temsilini öğrenebilen iki özdeş yapay sinir ağından oluşur (Bromley ve ark., 1993). İleri beslemeli algılayıcı olan sinir ağları eğitim sırasında hata geri yayılımını kullanılır. Sinir ağları paralel olarak çalışır ve genellikle bir mesafe metriği ile çıktıları karşılaştırılır. Sinir ağlarının girişine birbirine çok benzeyen, başka bir ifadeyle aynı sınıfa ait girdiler verildiğinde üretilen çıktı (mesafe metriği ile hesaplanır) bu iki girdinin aynı kaynağa ait olduğunu gösterecektir. Aynı şekilde farklı girdiler kullanıldığında aradaki mesafe fazla olacaktır. Bir siyam sinir ağı tarafından üretilen çıktı, iki giriş vektörünün öngörülen gösterimi arasındaki anlamsal benzerlik olarak düşünülebilir.


Siyam sinir ağları; konuşma işleme (Thiolliere ve ark., 2015; Gündoğdu ve ark., 2017), biyoloji (Jindal ve ark., 2017; Zheng ve ark., 2019), kimya ve farmakoloji (Jeon ve ark., 2019), geometri ve grafikler (Sun ve ark., 2020), görüntü analizi (Taigman ve ark., 2014; Liu ve ark., 2019b), yazı tanıma (Bromley ve ark., 1993; Koch ve ark., 2015), biyomedikal (Wang ve ark., 2017; Liu ve ark., 2019a; Zeng ve ark., 2019), optik (Zou ve ark., 2018) ve robotik (Utkin ve ark., 2017) gibi çok farklı alanlarda kullanılmıştır.

Tez kapsamında sınırlı veri seti ile yenidoğan termal görüntülerinden hastalıklarının tespit edilmesi konusuna örnek alınan çalışmalardan birinde Koch ve ark., tek-atış öğrenme ile görüntü tanıma için SSA'nı kullanmıştır. 50 farklı alfabedeki karakterlerin 20 kişi tarafından yazılmasıyla elde edilen sınıflar arası veri dengesi bulunmayan omniglot veri setinin yer aldığı çalışmada ikiz ağ modeli evrişimli olarak tasarlanmıştır (Koch ve ark., 2015). Çalışmada tek atış öğrenme konsepti çerçevesinde, verileri arka plan ve değerlendirme setlerine ayrılmış ve az sayıda veri örneği içeren değerlendirme setindeki görüntüler SSA ile sınıflanmıştır.

Şekil 3.18'de Siyam sinir ağlarının genel uygulama prensibi, Şekil 3.19'da ise tipik bir Siyam sinir ağı modelinin akış şeması gösterilmiştir.



Şekil 3.18. Siyam sinir ağlarının genel uygulama prensibi (Veriler soldan sağa doğru işlenmektedir. Mesafe metriğinin değeri, son çıktı olarak giriş veri çifti arasındaki benzerliğin bir ölçüsüdür)



Şekil 3.19. Siyam sinir ağları için uygulama akış diyagramı

İleri beslemeli bir sinir ağında, birinci katmanın her bir nöronu bir girdi değerini okur, bunu bir ağırlıkla çarpar ve sonucu sonraki katmandaki tüm nöronlara gönderir. Giriş katmanının dışındaki her katmanın nöronları aynı işi yapar ve sonuçları bir sonraki

katmanın nöronlarına aktararak son katmana kadar gönderir. Son katman sonuçlarını sinir ağı sonucunu üreten tek nörondan oluşan çıktı katmanına gönderir. Eğitim sırasında sinir ağı tarafından üretilen değerler, karşılık gelen gerçek değerlerle karşılaştırılır ve istatistiksel hata hesaplanır. Daha sonra sinir ağı, hatayı önceki katmanlara geri gönderir ve nöron ağırlıklarını buna göre, hata geri yayılımı adı verilen bir teknikle günceller. SSA da uygulama süreci olarak hata geri yayılımlı ileri beslemeli sinir ağı gibi çalışmaktadır. Siyam sinir ağı mimarisi, paralel olarak çalışan, çıktıları birleştirilmiş iki özdeş ileri beslemeli sinir ağı içerir (Şekil 3.18). Her sinir ağı geleneksel bir algılama modeli içerir. Eğitim sırasında karşılaştırılan görüntüler ağırlıkların paylaşıldığı Siyam sinir ağı ikizlerine beslenmekte ve klasik ileri yayılımla öğrenilen ağırlıklar hata geri yayılımı yoluyla güncellenir ve son konvolüsyon katmanından öğrenilen özelliklere göre bir çıktı oluşturulur. Her iki simetrik ağıın çıktıları düzleştirme katmanında özellik vektörleri olarak ifade edilmektedir. Bu iki özellik vektörü seçilen mesafe metriği ile karşılaştırılır. SSA ikizleri yaygın olarak ESA mimarisi kullanılarak oluşturulur ve konvolüsyon, havuzlama, seyreltme gibi işlemleri gerçekleştirir. Mesafe metriği olarak da Öklid uzaklığı (Eşitlik 3.15) veya mutlak fark (Eşitlik 3.16) gibi yöntemler kullanılır.

$$E_d = \|a - b\| = \sqrt{\sum_{i=0}^n (a_i - b_i)^2} \quad (3.15)$$

$$M_f = |a - b| = \sum_{i=0}^n (a_i - b_i) \quad (3.16)$$


Model eğitildikten sonra, görüntülerin aynı sınıfa ait olup olmadığına karar vermek mesafe metriğinden bir "d" eşliğine bağlı benzerlik indeksi oluşturulmaktadır. Daha düşük bir benzerlik indeksi, görüntülerin farklı olduğu anlamına gelirken, daha yüksek bir benzerlik indeksi, görüntülerin eşleştiğini ifade eder.

3.2.4.1. Tek atış öğrenme yaklaşımı

İnsan öğrenme davranışları yeni kalıplar edinme ve genelleme yapma konusunda güçlü bir yetenek sergilemektedir. İnsanların yeni kavramları hızlı bir şekilde anlayabilme ve daha sonra belirli bir kavram sınıfının görünmeyen örneklerine genelleme yapabilme kabiliyeti dikkat çekicidir (Fei-Fei ve ark., 2006). Örnek vermek gerekirse avokado gibi belirli bir türün bir görüntüsünü ilk kez gören bir kişi bu görüntüyü yeni

avokado görüntülerini tanımlamak için kullanmakla kalmaz, aynı zamanda mango gibi yakın türlerin görüntüleri hakkında eğitilmiş tahminler de yapılabilir. İnsanların sadece bir örnek üzerinden nesneler veya durumlar hakkında çıkarım yapabilme becerisinden yola çıkılarak tek atış öğrenme yaklaşımları ortaya çıkmıştır.

Makine öğrenimi uygulamaları için görüntülerden iyi özellikleri öğrenme süreci hesaplama açısından çok maliyetli ve çok az verinin olduğu durumlarda kullanışsız olmaktadır (Koch ve ark., 2015). Tek atış öğrenme konsepti genel olarak denetimli bir yaklaşımla görüntü temsillerini öğrenmeye, devamında ise hiç görülmemiş görüntü örneklerini ağız yeniden eğitimi gerektiksizin sınıflamaya dayalıdır. Bir test örneği hakkında bir tahmin yapmadan önce olası sınıfların yalnızca bir ya da birkaç örneğinin görülebildiği kısıtlı durum altındaki sınıflama görevleri tek atış öğrenme olarak tanımlanır. Şekil 3.20'deki örnek şema MNIST veri seti ile rakam sınıflama görevini temsil etmektedir. Bir tek atış görevinde, SSA, test görüntüsünü değerlendirme setindeki karşılaştırıldığı görüntüler içinden en çok benzediğini düşündüğü görüntüyle aynı sınıfa atar.



Şekil 3.20. Örnek tek atış öğrenme yaklaşımı.

Verilen örneğin sol taraftaki “0” rakamının, sağ taraftaki 3x3 lük rakam matrisinde birer örneği bulunan 9 farklı olası sınıftan ($N=9$) birine sınıflanabilmesi için makine öğrenmesi veya derin öğrenme yöntemlerine ihtiyaç duyulmaktadır. Klasik yöntemler, sınıf başına sadece bir ya da birkaç eğitim görüntüsü ile (burada 9 farklı sınıftan 9 eğitim örneği olarak düşünülebilir) yeterli doğrulukta sınıflama gerçekleştirememektedir.

Tek atış öğrenme yaklaşımı için yaygın olarak SSA kullanılmaktadır. Şekil 3.21’de verilen 9-yollu tek atış görevinde örneklerin her biri SSA’nın girdileri olması durumunda aralarındaki benzerlik skoruna bakılarak en yüksek skorun elde edildiği sınıfa dahil olduğu çıkarımı yapılmaktadır.



Şekil 3.21. 9-yollu tek atış öğrenme görevi örneği

3.3. Veri Artırımı Teknikleri

Makine öğrenmesi ve derin öğrenme yöntemleri, yapıları itibarıyla verilen bir veri kümesinin özelliklerini çıkarmak için tasarlanmıştır ve sınıflama, bilgisayarla görü gibi görevlerde oldukça kullanışlıdır. Ancak, küçük veri kümeleri modellerin veriyi ezberlemesine (aşırı uyum) ve sınıflama başarımının düşmesine neden olmaktadır. Aşırı uyum probleminden üstesinden gelebilmek için büyük veri kümelerine gereksinim duyulmaktadır. Medikal görüntü analizi gibi birçok uygulama alanının, büyük veri kümelerine erişimi yoktur.

Veri artırımı, orijinal verilerin değiştirilmesiyle yeni veri noktaları üretme işlemine verilen genel isimdir. Yapay zekâ çalışmalarında veri artırımı, ön işlem sürecinin bir parçası olarak düşünülebilir. Görüntüler için, döndürme, öteleme, kırpmaya, soldurma, ölçeklendirme; sesler için frekans maskeleyme, ölçeklendirme; metinler için eş anlamlısıyla değiştirme, rastgele kelime silme vb. çeşitli teknikler ile işlenmiş sentetik kopyalar oluşturulmaktadır. Bu kopyaların mevcut eğitim verisine eklenmesiyle büyük bir eğitim veri seti elde etmek mümkündür. Veri artırımı yapılmasının amacı modeli yeterince veri ile destekleyerek daha isabetli tahminler yapmasını sağlamaktır.

Veri artırma yöntemleri; geleneksel teknikler (Örn., aynalama, yakınlaştırma, ölçekleme, eğme kaydırma, döndürme, histogram eşitleme, keskinleştirme, bulanıklaştırma ve karşıtlık değiştirme vb.) ve gelişmiş teknikler (Örn., doku ve stil transferi yapma) olmak üzere iki gruba ayrılabilir. Geleneksel yöntemler kolay uygulanabilir, işlem ve zaman maliyetleri düşük yöntemlerken; doku ve stil transferi gibi gelişmiş yöntemler ise yine geniş veri setlerine ihtiyaç doğuran, işlem ve zaman maliyetleri yüksek yöntemlerdir. Bu tez çalışmasında geleneksel veri artırma yöntemleri kullanılmıştır.

$$\text{Parlaklık Artırma; } B(i, j) = f(i, j) + (a) \quad (3.17)$$

$$\text{Karşıtlık Değiştirme; } C(i, j) = f(i, j) * (b) \quad (3.18)$$

$$\text{RGB-Gri Seviye Dönüşümü; } G(i, j) = \frac{R_f(i, j) + G_f(i, j) + B_f(i, j)}{3} \quad (3.19)$$

$$\text{Keskinleştirme; } S(i, j) = f(i, j) + \tau * H(i, j) \quad (3.20)$$

burada $f(i, j)$ gerçek piksel değerlerini, (a) ışık miktarını ve (b) kontrast katsayısını temsil eder. Bu çalışmada, (a) ve (b) deneysel olarak sırasıyla 0.3 ve 0.5 olarak seçilmiştir. RGB görüntüsünün gri seviye eşdeğeri elde edilirken, R, G ve B alt görüntülerinin her piksel değeri alınmış ve çıktı olarak bu pikselin parlaklığını yansıtan tek bir değer elde edilmiştir. Bu uygulamada, üç kanaldaki değerlerin ortalaması alınmıştır. Netlik, farklı renkler arasındaki kontrast olarak ifade edilir. Tersine, görüntüleri keskinleştirmek, farklı renklerin kesiştiği kenarların kontrastını artırmak anlamına gelir. τ terimi tipik olarak 0 ila 2 arasında değişen bir ayarlama parametresini temsil eder; yüksek τ değerleri istenmeyen etkilere neden olabilir. Ek olarak, $H(i, j)$ bir yüksek geçiren filtre uygulamak için kullanılır.

3.4. Değerlendirme Kriterleri

Sınıflama uygulamalarının performansını ölçmek için genellikle duyarlılık, özgüllük ve doğruluk değerleri kullanılmıştır. Bu çalışmada incelenen literatürdeki birçok uygulamada sonuçları doğruluk, özgüllük, duyarlılık ve kesinlik değerlerinin hesaplanması ile karşılaştırılmıştır.

İki sınıflı sınıflayıcıların performansını değerlendirmek amacıyla kullanılan doğruluk, duyarlılık ve özgüllük değerleri sırasıyla Eşitlik 3.21, Eşitlik 3.22 ve Eşitlik 3.23 ile hesaplanmıştır. Doğruluk, duyarlılık ve özgüllük yüzde olarak gösterilmiştir.

Doğru Pozitifler (DP): Hasta etiketli bir verinin sınıflama algoritması tarafından hasta olarak sınıflanması.

Doğru Negatifler (DN): Sağlıklı etiketli verinin sınıflama modeli tarafından sağlıklı olarak sınıflanması.

Yanlış Pozitifler (YP): Sağlıklı olarak etiketlenmiş verinin model tarafından hasta olarak sınıflanması.

Yanlış Negatifler (YN): Hasta olarak etiketlenen verinin model tarafından sağlıklı olarak sınıflanması.

Doğru sınıflanan durumların, tüm durumlara oranı, doğruluk değerini ifade etmektedir.

$$\text{Doğruluk (\%)} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.21)$$

Doğru pozitif sonuçların, doğru pozitif ve yanlış negatif sonuçların toplamına oranı duyarlılık değerini göstermektedir.

$$\text{Duyarlılık (\%)} = \frac{DP}{DP + YN} \quad (3.22)$$

Doğru negatif sonuçların, doğru negatif ve yanlış pozitif sonuçların toplamına oranı özgüllük değerini ifade etmektedir.

$$\text{Özgüllük (\%)} = \frac{DN}{DN + YP} \quad (3.23)$$

Daha yüksek oranlar iyi bir yapay zekâ algoritmasının göstergesidir. Bununla birlikte, kötü sonuçlar çıkarmaktan kaçınmak için performans ölçütlerini tek tek değil bir bütün olarak incelemek büyük önem taşımaktadır.

Çizelge 3.3'te iki sınıflı sınıflayıcılar için örnek bir karmaşıklık matrisi verilmiştir.

Çizelge 3.3. İki sınıflı sınıflayıcılar için karmaşıklık matrisi

		Gerçek Değer	
		Pozitif (Hasta)	Negatif (Sağlıklı)
Tahmin Edilen Değer	Pozitif (Hasta)	Doğru Pozitif - DP	Yanlış Pozitif - YP
	Negatif (Sağlıklı)	Yanlış Negatif - YN	Doğru Negatif - DN

Sınıf sayısının ikiden fazla olduğu durumlarda, değerlendirme ölçütlerini farklı bir yaklaşımla değerlendirmek gerekir (Tharwat, 2020). Çok sınıflı sınıflama çalışmaları için karmaşıklık matrisi yapısı Çizelge 3.4'te gösterildiği gibidir.

Çizelge 3.4. Çok sınıflı sınıflayıcılar için karmaşıklık matrisi

		Gerçek sınıf			
		Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4
Tahmin edilen sınıf	Sınıf 1	D_{1,1}	E _{2,1}	E _{3,1}	E _{4,1}
	Sınıf 2	E _{1,2}	D_{2,2}	E _{3,2}	E _{4,2}
	Sınıf 3	E _{1,3}	E _{2,3}	D_{3,3}	E _{4,3}
	Sınıf 4	E _{1,4}	E _{2,4}	E _{3,4}	D_{4,4}

Çizelgeye göre D_{1,1}, D_{2,2}, D_{3,3}, D_{4,4} tüm sınıflar için doğru sınıflanmış örneklerin sayısını vermektedir. E_{1,2}, sınıf 1'de olması gerekirken sınıf 2 olarak tahmin edilen örneklerin sayısını ifade etmektedir. Bu nedenle, ilk sınıftaki yanlış sınıflanmış (EN₁) örnek sayısı sınıf 2, 3 veya 4 olarak tahmin edilen E_{1,2}, E_{1,3} ve E_{1,4}'ün toplamıdır (Eşitlik 3.24). 1. sınıf için yanlış sınıflanmış pozitifler (EP₁) ise Eşitlik 3.25 ile hesaplanır.

$$EN_1 = E_{1,2} + E_{1,3} + E_{1,4} \quad (3.24)$$

$$EP_1 = E_{2,1} + E_{3,1} + E_{4,1} \quad (3.25)$$

Elde edilen karmaşıklık matrisine göre, çok sınıflı sınıflayıcılar için duyarlılık (Eşitlik 3.26), kesinlik (Eşitlik 3.27) ve doğruluk (Eşitlik 3.28) değerleri hesaplanır.

$$Duyarlilik_{sınıf1} = \frac{D_{1,1}}{D_{1,1} + E_{1,2} + E_{1,3} + E_{1,4}} \quad (3.26)$$

$$Kesinlik_{sınıf1} = \frac{D_{1,1}}{D_{1,1} + E_{2,1} + E_{3,1} + E_{4,1}} \quad (3.27)$$

$$Dogruluk = \frac{D_{1,1} + D_{2,2} + D_{3,3} + D_{4,4}}{Tüm durumlar} \quad (3.28)$$

Karmaşıklık matrisi, gerçek değerleri bilinmekte olan bir dizi test verisi üzerinde, bir sınıflama modelinin performansını tanımlamak için kullanılan bir araç olarak tanımlanmaktadır. Karmaşıklık matrisinde, verilerin gerçek sınıfları ve sınıflayıcı tarafından tahmin edilen değerler yer almaktadır.

3.4.1. K-katlamalı çapraz doğrulama yöntemi

Sınıflama uygulamalarında genellikle veri seti iki parçaya bölünür ve parçalardan ilkinde eğitim algoritması özellik öğrenmesini gerçekleştirir. İkinci parça ise önerilen yöntemin test edilmesi için ayrılır. Çapraz doğrulama, sınırlı bir veri örneğinde makine öğrenmesi veya derin öğrenme modellerini değerlendirmek için kullanılan bir yeniden örnekleme prosedürüdür (Kohavi, 1995).


K-katlamalı çapraz doğrulamada, belirli bir veri örneğinin bölüneceği grupların sayısını ifade eden tek bir parametreye (k) sahiptir. Çapraz doğrulamanın temel biçimi k -katlamalı çapraz doğrulama olarak adlandırılır. K -katlamalı çapraz doğrulama yönteminde, boyutu “ D ” ile temsil edilen veri seti, her birinde yaklaşık eşit veri örneği bulunan k parçaya bölünür ($D_1, D_2, \dots, D_k$).

$$D_k = \frac{D}{k} \quad (3.29)$$

Eşitlik 3.29’da k . parçada bulunan örnek sayısı D_k olarak verilmiştir. Her işlemde, k adet parçaya bölünmüş veri setlerinin biri test verisi olarak ayrılırken, kalan $k - 1$ parça eğitim verisi olarak kullanılır. Yöntem k kez tekrarlandıktan sonra her bir aşamada elde edilen değerlerin ortalaması alınarak genel sınıflama sonucu elde edilir.

Şekil 3.22’de k değerinin 5 olarak belirlendiği durumda 5-katlamalı çapraz doğrulama işlemi görselleştirilmiştir. 5 katlamalı çapraz doğrulama prosedüründe ortalama başarımlar Eşitlik 3.30’da gösterildiği gibi hesaplanmaktadır.

$$Başarıml_{ort} = \frac{1}{5} \sum_{i=1}^5 Başarıml_i \quad (3.30)$$



Şekil 3.22. 5-katlamalı çapraz doğrulama prosesi

Bu işleme göre tüm veri seti 5 eşit parçaya bölünmüş ve ağın eğitimi için bu 5 parçadan 4 tanesi kullanılmıştır. Doğrulama için ayrılan parça ile başarımlar test edilmiş ve test işlemi bittiğinde bu kez doğrulamada kullanılan parça eğitim kümesine dahil edilirken eğitim kümesindeki ikinci parça doğrulama kümesine alınmaktadır. Süreç beş kez tekrarlandığında veri setinde bulunan tüm veriler hem eğitim hem de doğrulamada kullanılmış olur. Böylece modelin performans ölçümlerinin güvenilirliği sağlanır. Tez kapsamında gerçekleştirilen uygulamalarda 5-katlamalı çapraz doğrulama kullanılmıştır.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde tez çalışması kapsamında gerçekleştirilen “kardiyovasküler hastalıklar, pulmoner anomaliler ve abdominal & renal hastalıkların evrişimli sinir ağları ile sınıflanması”, “evrişimli sinir ağları ve veri artırımı teknikleri kullanılarak yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi”, “sınırlı termal veri ile yenidoğanlarda pulmoner anomalilerin diğer hastalıklardan ayırt edilmesi” ve “siyam sinir ağları ve tek atış öğrenme ile sınırlı termal veri seti kullanarak yenidoğan hastalıklarının sınıflanması” uygulamaları açıklanmıştır.

4.1. Kardiyovasküler Hastalıklar, Pulmoner Anomaliler ve Abdominal & Renal Hastalıkların Evrişimli Sinir Ağları ile Sınıflanması

Bu çalışmada, tam bağlı katmanında YSA ve DVM kullanılan ESA ile kardiyovasküler hastalıklar, pulmoner anomaliler, abdominal & renal hastalıklar ve prematüriteden oluşan veri seti ile sınıflama yapılmıştır. Veri setinde sınıflama çalışmasında kullanılacak hastalık sınıfları;

- Benzer geometride termal asimetriye yol açması beklenen veya
- Aynı vücut bölgesin etkileyeceği varsayılan hastalıklar aynı kategoride değerlendirilecek şekilde organize edilmiştir.

Uygulama klasik ESA mimarisinin sınırlı (az ve dengesiz) veri setlerinde vereceği sınıflama başarımını ölçmeyi amaçlamaktadır. Bu nedenle dört hastalık sınıfı bir kümeye, kalan üç sınıf diğer kümeye tanımlanarak iki küme arası veri dengesizliği oluşturulmuştur. Veri setinde bulunan üç hastalık sınıfı (PA, KrdH, ARH) ayrı ayrı diğer tüm hastalıkların birleşiminden oluşan küme ile sınıflama çalışmasının girdilerini oluşturmuş ve üç adet sınıflama uygulaması ortaya çıkmıştır (Şekil 4.1).

4.1.1. Oluşturulan 4 sınıflı veri seti

Uygulamada her bebekten 5'er görüntü ve her bebekten 20'şer görüntü kullanılarak iki farklı veri sayısı yaklaşımı (sırasıyla 220 ve 880 görüntü) ve tam bağlı ağ katmanında YSA ve DVM algoritmaları ile iki farklı sınıflama yaklaşımı kullanılmıştır.

Kullanılan veri seti, 16'sında PA, 10'unda KrdH, 8'inde ARH ve 10'u PRM olan toplam 44 yenidoğanın 880 görüntüsünü içermektedir.

Çizelge 4.1'de ilgi bölgelerine göre oluşturulan sınıflar ve bu sınıflar için uzmanlar tarafından verilen etiketler ile yenidoğan sayıları gösterilmektedir.

Çizelge 4.1. ESA ile ikili sınıflama uygulaması veri seti

Sınıf	Yenidoğan Sayısı	Etiket
Sınıf 1 Pulmoner Anomaliler	16	Pnömotoraks, TTN, RDS, ÖA
Sınıf 2 Kardiyovasküler Hastalıklar	10	KKH, PDA, AK, PH, HSK, PAB
Sınıf 3 Abdominal & Renal Hastalıklar	8	İAtr, İO, NEC, Diyafram Hernisi, Böbrek Yetmezliği
Sınıf 4 Prematürite	10	Düşük doğum ağırlıklı, hastalık teşhisi koyulmamış yenidoğanlar


Çizelge 4.2'de ise veri setinde bulunan görüntülere uzmanlar tarafından verilen etiketler ve bu etiketlere göre oluşturulan sınıflar ayrıntılı olarak verilmiştir.

Çizelge 4.2. Veri setinde bulunan sınıflar ve hastalık etiketleri

S.No	Yenidoğan	Etiket	Sınıf
1	Yenidoğan 01	RDS	PA Sınıf 1
2	Yenidoğan 02	RDS	
3	Yenidoğan 03	RDS	
4	Yenidoğan 04	RDS	
5	Yenidoğan 05	RDS	
6	Yenidoğan 06	RDS	
7	Yenidoğan 07	RDS	
8	Yenidoğan 08	RDS	
9	Yenidoğan 09	RDS	
10	Yenidoğan 10	RDS	
11	Yenidoğan 11	ÖA	
12	Yenidoğan 12	TTN	
13	Yenidoğan 13	TTN	
14	Yenidoğan 14	Pnömotoraks	
15	Yenidoğan 15	RDS	
16	Yenidoğan 16	ÖA	
17	Yenidoğan 17	PDA	KrdH Sınıf 2
18	Yenidoğan 18	HSK	
19	Yenidoğan 19	AK	
20	Yenidoğan 20	PDA	
21	Yenidoğan 21	PAB	
22	Yenidoğan 22	KKA	
23	Yenidoğan 23	AK	
24	Yenidoğan 24	KKA	
25	Yenidoğan 25	ASD-VSD	
26	Yenidoğan 26	PH	
27	Yenidoğan 27	NEC	ARH Sınıf 3
28	Yenidoğan 28	NEC	
29	Yenidoğan 29	IO	
30	Yenidoğan 30	Diyafram Hernisi	
31	Yenidoğan 31	NEC	
32	Yenidoğan 32	IATR	
33	Yenidoğan 33	NEC	
34	Yenidoğan 34	Böbrek Yetmezliği	
35	Yenidoğan 35	Prematüre	PRM Sınıf 4
36	Yenidoğan 36	Prematüre	
37	Yenidoğan 37	Prematüre	
38	Yenidoğan 38	Prematüre	
39	Yenidoğan 39	Prematüre	
40	Yenidoğan 40	Prematüre	
41	Yenidoğan 41	Prematüre	
42	Yenidoğan 42	Prematüre	
43	Yenidoğan 43	Prematüre	
44	Yenidoğan 44	Prematüre	


4.1.2. Sınıflama görevleri ve ESA modeli

Uygulamada üç hastalık sınıfı da ayrı ayrı diğer kalan sınıfların oluşturduğu küme ile karşılaştırılarak üç adet sınıflama görevi tanımlanmıştır. Şekil 4.1’de bu görevler için iki ayrı kümeye ayrılan veri setinin nasıl organize edildiği gösterilmiştir.



Şekil 4.1. Uygulamada karşılaştırılan sınıflara göre tanımlanan sınıflama görevleri

Uygulamada 44 yenidoğandan alınan görüntüler kullanılmıştır. Her yenidoğandan 5'er görüntü ve 20'şer görüntü alınarak iki farklı yaklaşımla sınıflama yapılmıştır. Görüntüler eğitim ve test kümesi olarak ayrılmış, 5'er görüntülük yaklaşım için 220 görüntüden 70 tanesi, 20'şer görüntülük yaklaşım için ise 880 görüntüden 280 tanesi test setinde değerlendirme amacıyla kullanılmıştır (Şekil 4.2).




Şekil 4.2. Eğitim ve test kümelerinin bölünmesi

Çizelge 4.3'te veri sayısı yaklaşımlarına göre karşılaştırılan kümelerin nasıl kategorize edildiği açıklanmıştır. Prematüre yenidoğan haricindeki sınıfların tamamı (Sınıf 1, Sınıf 2 ve Sınıf 3) ayrı ayrı ve kalan tüm sınıfların birleşiminden oluşan küme ile ESA'nın girdilerini oluşturmaktadır.

Çizelge 4.3. Yaklaşım I ve yaklaşım II'de karşılaştırılan sınıflar ve görüntü sayıları


	Küme 1		Küme 2	
	Hastalık Sınıfı	Görüntü sayısı	Hastalık Sınıfı	Görüntü sayısı
Yaklaşım I (5' er görüntü)	Pulmoner Anomaliler Sınıf 1	16 yenidoğan 80 görüntü	Diğer Sınıflar (Sınıf 2,3 ve 4)	28 yenidoğan 140 görüntü
	Kardiyovasküler Hastalıklar Sınıf 2	10 yenidoğan 50 görüntü	Diğer Sınıflar (Sınıf 1,3 ve 4)	34 yenidoğan 170 görüntü
	Abdominal & Renal Hastalıklar Sınıf 3	8 yenidoğan 40 görüntü	Diğer Sınıflar (Sınıf 1,2 ve 4)	36 yenidoğan 180 görüntü
Yaklaşım II (20' şer görüntü)	Pulmoner Anomaliler Sınıf 1	16 yenidoğan 320 görüntü	Diğer Sınıflar (Sınıf 2,3 ve 4)	28 yenidoğan 560 görüntü
	Kardiyovasküler Hastalıklar Sınıf 2	10 yenidoğan 200 görüntü	Diğer Sınıflar (Sınıf 1,3 ve 4)	34 yenidoğan 680 görüntü
	Abdominal & Renal Hastalıklar Sınıf 3	8 yenidoğan 160 görüntü	Diğer Sınıflar (Sınıf 1,2 ve 4)	36 yenidoğan 720 görüntü

Uygulamada YYBÜ’nde elde edilen termogramlar otomatik olarak artırılmış ve önerilen ESA modelinin girdilerini oluşturmuştur. Gerçekleştirilen uygulamanın genel blok gösterimi Şekil 4.3’te verilmiştir.



Şekil 4.3. Yenidoğan hastalıklarının evrişimli sinir ağı ile ikili sınıflanmasına ilişkin blok gösterim

Şekil 4.4’te uygulamada kullanılan ESA modeli verilmiştir. Konvolüsyon, aktivasyon ve havuzlama işlemleri görüntüden özellik çıkarma, modeli doğrusal olmayan hale getirme ve özellik azaltma kısımlarını oluşturmaktadır. Tam bağlı katman ise elde edilen özellik haritalarının sınıflanmasını gerçekleştiren katmandır. Tam bağlı ağ katmanında sınıflama algoritması olarak YSA ve DVM kullanılarak iki ayrı metod uygulanmıştır.



Şekil 4.4. Kardiyovasküler hastalıklar, pulmoner anomaliler ve abdominal & renal hastalıkların sınıflanmasında kullanılan ESA modeli

ESA modeli uygulaması PYTHON platformunda, her iterasyon güncellemesinde 4 örnek (küme boyutu) kullanıldığında, epok sayısı 100 alınarak gerçekleştirilmiştir. Sınıflama için iki konvolüsyon, iki havuzlama, bir seyreltme, bir düzleştirme ve iki ağ katmanlı ESA modeli uygulanmıştır. Kullanılan ESA mimarisi Çizelge 4.4'te verilmiştir.

Çizelge 4.4. Uygulamada kullanılan ESA modeline ilişkin parametreler

Katman Numarası	Katman Türü	Konfigürasyon		
		Aktivasyon Fonksiyonu	Matris Boyutu	Derinlik
1	Giriş		64x64	1
2	Konvolüsyon	ReLU	3x3	32
3	Maksimum Havuzlama	-	2x2	1
4	Konvolüsyon	ReLU	3x3	32
5	Maksimum Havuzlama	-	2x2	1
6	Seyreltme	-	0.5	1
7	Düzleştirme	-	3136	1
8	Ağ Katmanı 1	ReLU	128	1
9	Ağ Katmanı 2	ReLU	64	1
10	Çıkış	Sigmoid	1	1

Veri artırma işlemi PYTHON tabanlı Keras kütüphanesinin bir fonksiyonu olan “ImageDataGenerator” işlevi ile otomatik olarak sınıflama sırasında normalize etme, eğme kaydırma, yakınlaştırma ve yatay döndürme yöntemleri kullanılarak gerçekleştirilmiştir. Bu işlev her epokta küme boyutu (4 örnek) kadar görüntü sınıflandırmaya eklemiştir.

4.1.3. ESA ile kardiyovasküler hastalıklar, pulmoner anomaliler ve abdominal & renal hastalıkların sınıflanması uygulamasının sonuçları

Uygulama sonucunda elde edilen doğruluk ve özgüllük değerleri Çizelge 4.5’te, karmaşıklık matrisleri ise Çizelge 4.6, Çizelge 4.7 ve Çizelge 4.8’de verilmiştir.

Çizelge 4.5. Elde edilen doğruluk ve özgüllük değerleri

Karşılaştırılan Sınıflar				Metrik	ESA _{YSA}	ESA _{DVM}
Yaklaşım I (5'er görüntü)	PA Sınıf 1	1. Sınıflama uygulaması	KrdH Sınıf 2	Doğruluk Özgüllük	0.614 0.955	0.643 1.000
			ARH Sınıf 3			
			PRM Sınıf 4			
	KrdH Sınıf 2	2. Sınıflama uygulaması	PA Sınıf 1	Doğruluk Özgüllük	0.771 0.873	0.557 0.709
			ARH Sınıf 3			
			PRM Sınıf 4			
	ARH Sınıf 3	3. Sınıflama uygulaması	PA Sınıf 1	Doğruluk Özgüllük	0.829 0.964	0.786 1.000
			KrdH Sınıf 2			
			PRM Sınıf 4			
Yaklaşım II (20'şer görüntü)	PA Sınıf 1	1. Sınıflama uygulaması	KrdH Sınıf 2	Doğruluk Özgüllük	0.793 0.973	0.643 1.000
			ARH Sınıf 3			
			PRM Sınıf 4			
	KrdH Sınıf 2	2. Sınıflama uygulaması	PA Sınıf 1	Doğruluk Özgüllük	0.793 0.908	0.611 0.777
			ARH Sınıf 3			
			PRM Sınıf 4			
	ARH Sınıf 3	3. Sınıflama uygulaması	PA Sınıf 1	Doğruluk Özgüllük	0.646 0.818	0.750 1.000
			KrdH Sınıf 2			
			PRM Sınıf 4			
Ortalama Doğruluk (%)				74.1	66.5	
Ortalama Özgüllük (%)				91.5	91.4	

Çizelge 4.6. Her üç sınıflama görevi için tam bağlı katmanda YSA ve DVM kullanımına göre elde edilen karmaşıklık matrisleri

		ESA _{YSA}			ESA _{DVM}				
		Gerçek değer			Gerçek değer				
			Pozitif	Negatif		Pozitif	Negatif		
Yaklaşım I	1. Sınıflama uygulaması	Tahmin edilen değer	Pozitif	0	25	Tahmin edilen değer	Pozitif	0	25
			Negatif	2	43		Negatif	0	45
	2. Sınıflama uygulaması		Pozitif	6	9		Pozitif	0	15
			Negatif	7	48		Negatif	16	39
	3. Sınıflama uygulaması		Pozitif	5	10		Pozitif	0	15
			Negatif	2	53		Negatif	0	55
		Gerçek değer			Gerçek değer				
			Pozitif	Negatif		Pozitif	Negatif		
Yaklaşım II	1. Sınıflama uygulaması	Tahmin edilen değer	Pozitif	8	52	Tahmin edilen değer	Pozitif	0	100
			Negatif	6	214		Negatif	0	180
	2. Sınıflama uygulaması		Pozitif	0	40		Pozitif	0	59
			Negatif	22	218		Negatif	49	171
	3. Sınıflama uygulaması		Pozitif	1	59		Pozitif	0	60
			Negatif	40	180		Negatif	0	180

Çizelge 4.7. Yaklaşım I ve II için ESA_{YSA} ile elde edilen karmaşıklık matrisleri

TOPLAM			
		Gerçek değer	
		Pozitif	Negatif
Tahmin edilen değer	Pozitif	11	11
	Negatif	44	144
Yaklaşım I (5'er veri)			
		Gerçek değer	
		Pozitif	Negatif
Tahmin edilen değer	Pozitif	29	68
	Negatif	151	612
Yaklaşım II (20'şer veri)			

Çizelge 4.8. Yaklaşım I ve II için ESA_{DVM} ile elde edilen karmaşıklık matrisleri

TOPLAM			
		Gerçek değer	
		Pozitif	Negatif
Tahmin edilen değer	Pozitif	0	16
	Negatif	55	139
Yaklaşım I (5'er veri)			
		Gerçek değer	
		Pozitif	Negatif
Tahmin edilen değer	Pozitif	0	49
	Negatif	220	531
Yaklaşım II (20'şer veri)			

Elde edilen sonuçlar incelendiğinde, Yaklaşım I ve Yaklaşım II birbirine yakın değerlendirme sonuçları verse de 880 görüntü kullanıldığında 220 görüntüye göre daha yüksek sınıflama başarımı elde edilmiştir. Doğruluk metriği bazı sınıflar için %60-65 aralığında bazı sınıflar için ise %80-85 aralığında elde edilmiştir. En başarılı sınıflama performansı (%83 doğruluk, %96 özgüllük) abdominal & renal hastalıklar ile diğer hastalıkların ayrımının yapıldığı durumda ortaya çıkmıştır.

Tam bağlı katmanda YSA kullanıldığında elde edilen sınıflama başarımı DVM ile karşılaştırıldığında üstündür.

Daha sonra yapılacak çalışmaların temelini oluşturacağı için bu uygulamada ESA tercih edilmiştir. Bu çalışma ile büyük veri setlerinde başarılı sonuçlar veren ESA'nın sınırlı veri setlerinde göstereceği performans değerlendirilmiştir. Sonuçlar incelendiğinde sınıflar arası veri dengesizliğinin yüksek olması durumunda yetersiz kaldığı görülmüştür.

4.2. Evrişimli Sinir Ağları ve Veri Artırımı Teknikleri Kullanılarak Yenidoğan Hastalıklarının Çok-Sınıflı Olarak Belirlenmesi

Bu çalışmada, veri artırımı ve ESA kullanılarak yenidoğan termogram veri seti ile çok sınıflı sınıflama çalışmaları yapılmıştır. Veri seti 44 yenidoğanın her birinden 20 görüntü alınarak oluşturulmuş ve dört farklı sınıfta incelenmiştir. Uygulamada

sınıflaması gerçekleştirilen hastalık sınıfları pulmoner anomaliler, kardiyovasküler hastalıklar, abdominal & renal hastalıklar ve prematüredir.

Ayrıca, çeşitli veri artırma teknikleri kullanılarak 880 görüntü 2380, 2680 ve 5080 görüntüye yükseltilmiştir. ESA modelinin ve veri artırımının sınıflama başarımına etkisini araştırmak amacıyla farklı veri sayısı ve veri dağılımı varyasyonlarının sonuçları incelenmiştir. Sonuçlar doğruluk, duyarlılık ve kesinlik metrikleri ile değerlendirilmiştir.


Çalışmada, hastalık etiketleri uzmanlar tarafından belirlenen yenidoğanlar pulmoner anomaliler, kardiyovasküler hastalıklar, abdominal & renal hastalıklar bulunanlar ve herhangi bir hastalık tanısı konmamış prematüre bebekler olmak üzere 4 gruba ayrılmıştır. Uygulamada, 44 yenidoğanın her birinin 20 görüntüsü rastgele seçilmiş ve orijinal veri kümesinde toplam 880 görüntü kullanılmıştır. Uzmanlar tarafından verilen hastalık etiketlerine göre aynı vücut bölgesinde termal değişiklik göstermesi beklenen hastalıklar ile aynı organları etkileyen veya aynı organlardan etkilenen hastalıklar 4 sınıflı veri seti içerisinde yer almıştır (Çizelge 4.9).

Çizelge 4.9. ESA ve veri artırımı teknikleri kullanılarak yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi uygulamasında kullanılan veri seti

Sınıf	Yenidoğan	Etiket	Veri Sayısı	Grup
1	001	RDS	16 yenidoğandan 320 termogram	PA Sınıf 1
	002	RDS		
	003	RDS		
	004	RDS		
	005	RDS		
	006	RDS		
	007	RDS		
	008	RDS		
	009	RDS		
	010	RDS		
	011	ÖA		
	012	TTN		
	013	TTN		
	014	Pnömotoraks		
	015	RDS		
	016	ÖA		
2	017	PDA	10 yenidoğandan 200 termogram	KrdH Sınıf 2
	018	HSK		
	019	AK		
	020	PDA		
	021	PAB		
	022	KKA		
	023	AK		
	024	KKH		
	025	ASD		
	026	PH		
3	027	NEC	8 yenidoğandan 160 termogram	ARH Sınıf 3
	028	NEC		
	029	İÖ		
	030	Diyafram Hernisi		
	031	NEC		
	032	İAtr		
	033	NEC		
	034	Böbrek Yetmezliği		
4	035	Prematüre	10 yenidoğandan 200 termogram	PRM Sınıf 4
	036	Prematüre		
	037	Prematüre		
	038	Prematüre		
	039	Prematüre		
	040	Prematüre		
	041	Prematüre		
	042	Prematüre		
	043	Prematüre		
	044	Prematüre		

4.2.1. Sınıflama yaklaşımları

Sınırlı ve dengesiz veri seti için doğru model ve yaklaşımlar belirlenerek yüksek sınıflama performansı elde etmek amacıyla görüntü artırma ile 6 farklı veri kümesi dağılımı yaklaşımı ESA ile sınıflanmıştır. Kullanılan sınıflama yaklaşımları Çizelge 4.10’da gösterilmiştir. Önerilen sisteme ilişkin blok gösterim Şekil 4.5’te verilmiştir.



Şekil 4.5. Önerilen ESA ve veri artırımı kullanılarak sınırlı veri ile çok sınıflı sınıflama uygulamasına ilişkin blok gösterim


Çizelge 4.10. Sınıflama yaklaşımları

Yaklaşım No	Veri Seti Boyutu	Eğitim Örneği (G x Y x K)	Test Örneği	Veri Arttırma	Açıklama
I	880	660 (15 x 44)	220 (5 x 44)	✗	Her bir yenidoğandan alınan 20'şer farklı görüntünün 15 tanesiyle model eğitilmiştir. Kalan 5 görüntü ile test edilmiştir.
II	880	220 (5 x 44)	660 (15 x 44)	✗	Her bir yenidoğandan alınan 20'şer görüntünün 5 tanesiyle model eğitilmiştir. Kalan 15 görüntü ile test edilmiştir.
III	880	600 (20 x 30)	280 (20 x 14)	✗	Eğitim ve test kümeleri tamamen birbirinden ayrılmıştır. Bir yenidoğana ait görüntüler eğitimde kullanıldıysa testte aynı yenidoğanın başka bir görüntüsüne yer verilmemiştir. 44 yenidoğanın 30 tanesi eğitimde 14 tanesi ise testte kullanılmıştır.
IV	2680	2400 (20 x 30 x 4)	280 (20 x 14)	✓	Eğitim ve test kümeleri tamamen birbirinden ayrılmıştır. Bir yenidoğana ait görüntüler eğitimde kullanıldıysa testte aynı yenidoğanın başka bir görüntüsüne yer verilmemiştir. 44 yenidoğanın 30 tanesi eğitimde 14 tanesi ise testte kullanılmıştır. Veri artırımı yapılarak eğitimde kullanılan veri sayısı 4 katına çıkarılmıştır.
V	2380	2100 $20 \times (5 + 25 \times 4)$	280 (20 x 14)	✓	Dengesiz olan veri setinin dengesini daha da bozmak için 4 sınıftan 3 tanesinde veri artırımı yapılmış, en az verinin bulunduğu 3. sınıfta (abdominal ve renal hastalıklar) veri sayısı sabit tutulmuştur.
VI	5080	4800 (20 x 30 x 8)	280 (20 x 14)	✓	Eğitim veri setindeki veri sayısı 3 farklı teknikle 2400'e çıkarılmıştı, Bu yaklaşımda ise 2400 görüntünün gri-seviye karşılıkları eklenerek 4800 görüntü elde edilmiş ve eğitim bu 4800 görüntü ile yapılmıştır.

G: 1 yenidoğandan alınan görüntü sayısı, Y: Yenidoğan sayısı, K: veri artırımı katsayısı


Uygulamada, yenidoğan yoğun bakım ünitesinde kaydedilen 880 orijinal görüntü çeşitli veri artırma teknikleri ile, IV. yaklaşımda 2680'e, V. yaklaşımda 2380'e ve VI. yaklaşımda 5080'e çıkarılmıştır.

Yaklaşım IV, V ve VI için veri artırma işlemleri, Şekil 4.6, Şekil 4.7 ve Şekil 4.8'de gösterilmiştir.




Şekil 4.6. IV numaralı yaklaşım için uygulanan veri artırma işlemi

Yaklaşım IV'te 600 eğitim görüntüsü farklı artırma teknikleri kullanılarak artırılmış ve 2680 görüntülük veri seti elde edilmiştir.



Şekil 4.7. V numaralı yaklaşım için uygulanan veri artırma işlemi


Yaklaşım V'te abdominal & renal hastalıklar sınıfına ait 100 görüntü dışında kalan 500 görüntü, veri artırma teknikleri ile artırılmıştır. Veri artırımı ile üretilen 1500 görüntüye, orijinal 600 görüntü ve test için ayrılan 280 görüntü eklendiğinde veri seti boyutu 2380'e çıkmıştır.



Şekil 4.8. VI numaralı yaklaşım için uygulanan veri artırma işlemi

Yaklaşım VI'da, farklı bir veri artırma tekniğinin etkilerini gözlemlemek için, 2400 RGB görüntüsünün gri-seviye karşılığı elde edilmiş böylece eğitim setindeki görüntü sayısı 4800'e yükseltilmiştir.

Veri artırma aşaması sonucunda elde edilen görüntü örnekleri Şekil 4.9'da gösterilmektedir.




Şekil 4.9. Veri artırma ile elde edilen görüntü örnekleri, a) gri seviye görüntü, b) keskinleştirme c) parlaklık geliştirme, d) karışıklık değiştirme

Bu çalışmada veri artırma tekniği olarak parlaklık artırma, karşıtlık değiştirme, RGB-gri seviye dönüşümü ve keskinleştirme kullanılmıştır.

4.2.2. ESA ve veri artırımı teknikleri ile çok sınıflı sınıflama uygulamasında kullanılan ağ modeli

ESA yapısı, evrişim katmanı ve tam bağlı ağ katmanı olan iki ana katman içermektedir. Evrişim katmanında konvolüsyon adımları ve havuzlama işlemleri olmak üzere iki süreç vardır. Konvolüsyon adımları ile görüntüdeki düşük veya yüksek seviyeli özelliklerin (keskin kenarlar, basit eğrisel çizgiler gibi) çıkarılması için 3×3 , 5×5 veya 7×7 gibi filtreler uygulanır. Havuzlama işlemi, havuzlama boyutu ve ortalama ve maksimum havuzlama gibi seçilen yöntemlere göre elde edilen özellik haritasının boyutundaki azalmayı ifade eder, özellik seçimi havuzlama işlemi tarafından yapılır. Önerilen ESA mimarisinde, 3×3 büyüklüğünde bir konvolüsyon filtresi ve 2×2 büyüklüğünde maksimum havuzlama çerçevesi tercih edilmiştir. Tam bağlı ağ katmanları, düzleştirme ve sınıflama olmak üzere iki bölümden oluşur. Düzleştirme katmanında elde edilen özellik matrisi, aynı zamanda, konvolüsyon katmanının çıktı matrisinin elemanlarından elde edilen bir özellik vektörüne dönüştürülür. Bu çıkarılan özellikler kullanılarak sınıflama katmanında bir aktivasyon fonksiyonuna bağlı olarak girişte verilen görüntünün hangi sınıfa dahil edileceği tahmin edilir. ESA mimarisi Şekil 4.10'da verilmiştir.



Şekil 4.10. Sınırlı veri ile çok sınıflı sınıflama uygulamasında kullanılan ESA modeli

Kullanılan ESA modeli 3 x 3 boyutlarında üç konvolüsyon katmanı, 2 x 2 boyutlarında üç maksimum havuzlama katmanı, 2304 nöron içeren bir düzleştirme katmanı ve sırasıyla 128 x 1, 64 x 1 ve 4 x 1 boyutlarında üç sınıflama ağ katmanı içermektedir. Tüm konvolüsyon ve maksimum havuzlama katmanlarına ReLU aktivasyon fonksiyonu uygulanmıştır. Birinci ağ katmanı 128, ikincisi 64 nörondan oluşurken, üçüncü ağ katmanı bu model için çıktı katmanı olarak adlandırılır ve hastalıkların sınıflanması için 4 nörondan oluşur. Çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılmıştır. Çıktı değerleri 1 ile 4 arasında değişmektedir. Elde edilen çıktı değerine bağlı olarak Çizelge 4.11’de belirtilen çıkarım gerçekleştirilir.

Çizelge 4.11. ESA çıktılarının yorumlanması

Sınıflama Çıktısı	Hastalık Sınıfı
1	Pulmoner anomaliler
2	Kardiyovasküler hastalıklar
3	Abdominal & renal hastalıklar
4	Prematürite

4.2.3. ESA ve veri artırımı ile yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi uygulamasının sonuçları

Bu çalışmada, yenidoğan yoğun bakım ünitesinde tedavi edilen bebeklerin hastalıklarını belirlemek için sınırlı termal görüntü veri seti ile çok sınıflı bir sınıflayıcı ESA modeli kullanılmıştır. Sınıflama çalışması sonuçları, farklı veri artırma yöntemleri ve eğitim-test seti dağılımları kullanılarak 6 farklı yaklaşım için karşılaştırılmıştır. Sınıflama doğruluğunu kanıtlamak için beş kat çapraz doğrulama yöntemi uygulanmış ve veriler 5 farklı “test” setine bölünmüştür. Her döngüde veri setinin 4/5’i ile eğitim verilirken 1/5 ile test edilmiş ve ilk test seti için karışıklık matrisi elde edilmiştir. Bu karışıklık matrisi, verilerimizin 1/5’inin sınıflama doğruluğunu temsil etmektedir. Her döngüde elde edilen tüm karışıklık matrislerinin toplanmasıyla elde edilen sonuçta ortaya çıkan karışıklık matrisi, bu çalışmada kullanılan tüm veriler için bu modelin performansını temsil etmektedir. Elde edilen karmaşıklık matrisleri ile doğruluk, duyarlılık ve kesinlik sonuçları Çizelge 4.12 ve Çizelge 4.13’te verilmiştir.

Çizelge 4.12. ESA ve veri artırımı ile yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi uygulamasında elde edilen karmaşıklık matrisleri

Yaklaşım I					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	370	15	0	0
	KrdH	25	230	10	0
	ARH	5	5	190	0
	PRM	0	0	0	250
Yaklaşım II					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	950	0	5	110
	KrdH	65	675	15	0
	ARH	70	75	510	10
	PRM	115	0	70	630
Yaklaşım III					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	400	0	80	20
	KrdH	100	215	25	0
	ARH	0	85	195	0
	PRM	0	0	0	280
Yaklaşım IV					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	454	22	13	10
	KrdH	12	235	20	0
	ARH	21	43	267	0
	PRM	13	0	0	290
Yaklaşım V					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	385	0	100	15
	KrdH	0	200	35	0
	ARH	115	100	100	0
	PRM	0	0	65	285
Yaklaşım VI					
Tahmin edilen sınıf		Gerçek sınıf			
		PA	KrdH	ARH	PRM
Tahmin edilen sınıf	PA	440	0	0	25
	KrdH	21	260	20	9
	ARH	39	40	280	3
	PRM	0	0	0	263

Çizelge 4.13. ESA ve veri artırımı ile yenidoğan hastalıklarının çok-sınıflı olarak belirlenmesi uygulamasında elde edilen duyarlılık, kesinlik ve doğruluk sonuçları

Yaklaşım	Grup	Etiket	Duyarlılık	Kesinlik	Doğruluk
I	Sınıf 1	PA	%92.50	%96.10	%94.55
	Sınıf 2	KrdH	%92.00	%86.79	
	Sınıf 3	ARH	%95.00	%95.00	
	Sınıf 4	PRM	%100.00	%100.00	
II	Sınıf 1	PA	%79.17	%89.20	%84.54
	Sınıf 2	KrdH	%90.00	%89.40	
	Sınıf 3	ARH	%85.00	%76.69	
	Sınıf 4	PRM	%84.00	%77.30	
III	Sınıf 1	PA	%80.00	%80.00	%77.86
	Sınıf 2	KrdH	%71.67	%63.24	
	Sınıf 3	ARH	%65.00	%69.64	
	Sınıf 4	PRM	%93.33	%100.00	
V	Sınıf 1	PA	%90.80	%90.98	%89.00
	Sınıf 2	KrdH	%78.33	%88.01	
	Sınıf 3	ARH	%89.00	%80.66	
	Sınıf 4	PRM	%96.67	%95.71	
VI	Sınıf 1	PA	%77.00	%77.00	%69.29
	Sınıf 2	KrdH	%85.11	%66.67	
	Sınıf 3	ARH	%31.75	%33.33	
	Sınıf 4	PRM	%81.43	%95.00	
VII	Sınıf 1	PA	%88.00	%94.62	%88.79
	Sınıf 2	KrdH	%86.67	%83.87	
	Sınıf 3	ARH	%93.33	%77.35	
	Sınıf 4	PRM	%87.67	%100.00	

4.3. Sınırlı Termal Veri ile Yenidoğanlarda Solunum Sistemi Anomalilerinin Diğer Hastalıklardan Ayırt Edilmesi

Yenidoğan yoğun bakım ünitesindeki vaka dağılımı incelendiğinde bazı hastalıklara sıklıkla rastlanırken, bazılarına nadiren rastlanır. Bu nadir hastalıkların yaygın hastalıklar kadar ölümcül olabileceği düşünüldüğünde, sınıflama yaklaşımlarının dengesiz dağılmış ve az sayıda veriyle yapılacak sınıflama çalışmasının önemi daha iyi anlaşılacaktır. Bu çalışmada solunum sıkıntısı sendromu, geçici taşipne, pnömotoraks, özofagus atrezisi gibi yenidoğanın solunum sistemine bağlı ve erken teşhisinin hayati sonuçları olan hastalıkların termal görüntüleme ve derin öğrenme teknikleri ile belirlenmesi amaçlanmıştır. ESA'nın sınıflama başarımını arttırmak ve solunum sistemine bağlı hastalıkların az sayıdaki örneğinin sınıflanması üzerine çeşitli veri artırma teknikleri uygulanarak sonuçları analiz edilmiştir.

4.3.1. Kullanılan veri seti


Uygulamada 34 yenidoğandan alınan görüntüler kullanılmıştır. ESA modelinin eğitimi için termal görüntülere parlaklık artırma, keskinleştirme ve kontrast değiştirme yöntemleri uygulanarak veri artırımı yapılmıştır. Her yenidoğanda 20 görüntü ile oluşturulan orijinal sınırlı veri kümesine ek olarak, arttırılmış bir veri kümesi elde edilmiş ve veri artırımının sınıflama sonuçları üzerindeki etkileri gözlenmiştir. Orijinal veri seti 34 yeni doğandan 680 termal görüntü içerirken, genişletilmiş veri seti 2060 termal görüntü içermektedir. Deney sonucunda, veri artırımının sınıflama doğruluğunu nasıl etkilediği incelenmiş ve karşılaştırmalı bir çalışma sunulmuştur.

Görüntüler 16'sı pulmoner anomalisi, 10'u kardiyovasküler hastalıkları, 8'i abdominal & renal hastalıkları olan 34 yenidoğandan elde edilmiştir. Uygulamada faydalanılan yenidoğanların sahip oldukları hastalıklar ve etiketlenen grup bilgileri Çizelge 4.14'te verilmiştir.

Çizelge 4.14. Solunum sistemi anomalilerinin belirlenmesi için oluşturulan veri seti

No	Yenidoğan	Etiket	Grup	Sınıf
1	Yenidoğan 1	RDS	Pulmoner Anomaliler	1
2	Yenidoğan 2	RDS		
3	Yenidoğan 3	RDS		
4	Yenidoğan 4	RDS		
5	Yenidoğan 5	RDS		
6	Yenidoğan 6	RDS		
7	Yenidoğan 7	RDS		
8	Yenidoğan 8	RDS		
9	Yenidoğan 9	RDS		
10	Yenidoğan 10	RDS		
11	Yenidoğan 11	ÖA		
12	Yenidoğan 12	TTN		
13	Yenidoğan 13	TTN		
14	Yenidoğan 14	Pnömotoraks		
15	Yenidoğan 15	RDS		
16	Yenidoğan 16	ÖA		
1	Yenidoğan 17	PDA	Kardiyovasküler Hastalıklar	2
2	Yenidoğan 18	HSK		
3	Yenidoğan 19	AK		
4	Yenidoğan 20	PDA		
5	Yenidoğan 21	PAB		
6	Yenidoğan 22	KKH		
7	Yenidoğan 23	AK		
8	Yenidoğan 24	KKH		
9	Yenidoğan 25	ASD		
10	Yenidoğan 26	PH		
11	Yenidoğan 27	NEC	Abdominal & Renal Anomaliler	
12	Yenidoğan 28	NEC		
13	Yenidoğan 29	IAtr		
14	Yenidoğan 30	Diyafram Hernisi		
15	Yenidoğan 31	NEC		
16	Yenidoğan 32	IAtr		
17	Yenidoğan 33	NEC		
18	Yenidoğan 34	Böbrek Yetmezliği		


Sınırlı termal veri ile yenidoğanlarda solunum sistemi anomalilerinin diğer hastalıklardan ayırt edilmesi uygulamasının aşamalarını gösteren blok diyagram Şekil 4.11'de verilmiştir.



Şekil 4.11. Solunum sistemi anomalilerin belirlenmesi uygulamasının genel blok gösterimi

ESA ile sınırlı sayıda veri içeren uygulamalar için veri artırma teknikleri kullanılarak sınıflama başarımının artırılması amaçlanmıştır. Bu çalışmada parlaklık artırma ve kontrast geliştirme yöntemleri kullanılmıştır. Orijinal veri setindeki 34 yenidoğandan alınan 680 adet yenidoğan termal görüntüsü öncelikle eğitim ve test kümelerine ayrılmıştır. İlk gruptaki 16 bebeğin 11, ikinci gruptaki 18 bebeğin 12 tanesinden alınan 460 görüntü eğitimde, kalan 11 yenidoğanın 220 görüntüsünden ise sınıflama performansının ölçümünde faydalanılmıştır.

Şekil 4.12'de blok gösterimi verilen veri artırma yöntemleri ile 460 görüntü 4 katına çıkarılarak 1840 görüntü elde edilmiştir.



Şekil 4.12. Solunum sistemi anomalilerin ESA ile belirlenmesinde veri artırma işlemi


Böylece toplam veri seti boyutu, test setindeki görüntülerle birlikte 2060 görüntü olarak güncellenmiştir.

Veri sayısı artırılırken parlaklık artırma (Eşitlik 4.1), kontrast değiştirme (Eşitlik 4.2) ve keskinleştirme (Eşitlik 4.4) yöntemleri kullanılmıştır.

4.3.2. Uygulamada kullanılan ağ modeli

Önerilen ESA mimarisi üç konvolüsyon, üç maksimum havuzlama ve üç ağ katmanı içermektedir. Girdi görüntülerinin boyutları 512 x 512'den 64 x 64'e getirildikten sonra ilk konvolüsyon katmanı 32 farklı 3 x 3 boyutlu filtre ile oluşturulmuştur (aktivasyon fonksiyonu: ReLU), ikinci ve üçüncü konvolüsyon katmanı ise 64 farklı 3 x 3 filtre ile elde edilmiştir. Kullanılan üç havuzlama katmanının çerçeve boyutları 2 x 2 olarak seçilmiştir (maksimum havuzlama). İlk iki ağ katmanı sırasıyla 128 ve 64 nörondan oluşturulmuştur (aktivasyon fonksiyonu: Relu) ve çıktı katmanı olarak adlandırılan üçüncü ağ katmanı ise (aktivasyon fonksiyonu = sigmoid) 0 ile 1 arasında değer almaktadır. Ağ katmanlarından elde edilen özellik vektörünün sınıflanması YSA ile “softmax” sınıflayıcı kullanılarak gerçekleştirilmiştir.

Önerilen ağ modeli Şekil 4.13'te, model parametreleri ise Çizelge 4.15'te verilmiştir.



Şekil 4.13. Solunum sistemi anomalilerin belirlenmesi uygulamasında kullanılan ESA modeli

Çizelge 4.15. Uygulamada kullanılan ESA modeline ilişkin parametreler

Katman Numarası	Katman Türü	Konfigürasyon		
		Aktivasyon Fonksiyonu	Boyut	Derinlik
1	Konvolüsyon	ReLU	3x3	32
2	Maksimum Havuzlama	-	2x2	-
3	Konvolüsyon	ReLU	3x3	64
4	Maksimum Havuzlama	-	2x2	-
5	Konvolüsyon	ReLU	3x3	64
6	Maksimum Havuzlama	-	2x2	-
7	Seyreltme	-	0.25	-
8	Düzleştirme		576	1
9	Ağ Katmanı	ReLU	128	1
10	Ağ Katmanı	ReLU	64	1
11	Ağ (Çıkış)	Softmax	1	1

4.3.3. Sınırlı veri ile yenidoğan pulmoner anomalilerinin diğer hastalıklardan ayırt edilmesi uygulamasının sonuçları

Bu çalışmada yenidoğanlarda solunum sistemi hastalıklarını belirlemek için ESA modeli ve veri artırma yöntemleri kullanılmıştır. Sınıflamada, çeşitli solunum sistemi anomalileri olan yenidoğanlar 1. sınıfı, diğer hastalıklara sahip yenidoğanlar (kardiyovasküler hastalıklar, abdominal ve renal anomalileri) 2. sınıfı oluşturmaktadır. Çalışmanın ilk bölümünde, sınıflama her bir yenidoğandan 20 görüntü ve 16 pulmoner anomali ve 18 diğer hastalıkları olan 34 bebeğin 680 görüntüsü ile yapılmıştır. İkinci bölümde, bebeklerin tüm görüntüleri ve farklı veri arttırma teknikleri ile elde edilen görüntüler kullanılmış ve 2060 görüntü ile sınıflama yapılmıştır.

Veri artırimsız sınıflama çalışması sonucunda elde edilen karmaşıklık matrisi Çizelge 4.16'da genişletilmiş veri seti ile termogramlar sınıflandığında ortaya çıkan karmaşıklık matrisi ise Çizelge 4.17'de verilmiştir.


Uygulamada değerlendirme kriteri olarak doğruluk, duyarlılık ve özgüllük kullanılmış ve ortaya çıkan sınıflama başarımı Şekil 4.14'teki grafikte gösterilmiştir.

Çizelge 4.16. Orijinal veri seti kullanıldığında elde edilen karmaşıklık matrisi.

		Gerçek sınıf	
		Pulmoner Anomali	Diğer Hastalıklar
Tahmin edilen sınıf	Pulmoner Anomali	80	14
	Diğer Hastalıklar	20	106

Çizelge 4.17. Artırılmış veri seti kullanıldığında elde edilen karmaşıklık matrisi.

		Gerçek sınıf	
		Pulmoner Anomali	Diğer Hastalıklar
Tahmin edilen sınıf	Pulmoner Anomali	80	0
	Diğer Hastalıklar	20	120



Şekil 4.14. Doğruluk, duyarlılık ve özgüllük sonuçları

Orijinal veri kümesi sonuçları %80 duyarlılık, %88 özgüllük, %85 doğruluk olarak elde edilmiştir. Termal görüntülerin sayısı 680'den 2060'a yükseltildiğinde sınıflama başarımının arttığı gözlenmektedir. Örneğin, doğruluk %85'ten %91'e yükselmiş ve özgüllük %100 olarak hesaplanmıştır.

Sonuçlar, veri artışı ile daha iyi sonuçlar alınmasının mümkün olduğunu ve kullanılan modelin termal görüntülerden yenidoğan hastalıklarının saptanması için uygun olduğunu göstermiştir.


4.4. Derin Siyam Ağları ve Tek Atış Öğrenme ile Sınırlı Termal Veri seti Kullanarak Yenidoğan Hastalıklarının Sınıflanması

Bu uygulamada siyam sinir ağları ile tek-atış öğrenme yaklaşımları kullanılarak sınıf sayısının fazla olduğu ve her sınıftan bir ya da birkaç örnek veri içeren termal görüntü veri seti ile verimli bir yenidoğan hastalıkları sınıflama metodu önerilmiştir.

Hastalıkların otomatik sınıflanması için yenidoğan yoğun bakım ünitesinde gözlem ve tedavi altında tutulan 67 yenidoğanın her birine ait 20'şer görüntüden oluşan toplam 1340 görüntülük veri seti kullanılmıştır. Çalışma kardiyovasküler hastalıklar (13 yenidoğan), özofagus atrezisi (5 yenidoğan), enfeksiyon hastalıkları (4 yenidoğan), intestinal atrezi (4 yenidoğan) nekrotizan enterokolit (6 yenidoğan), prematürite (17 yenidoğan), pulmoner anomaliler (18 yenidoğan) olmak üzere 7 farklı sınıftan yenidoğan görüntüleri ile gerçekleştirilmiştir (Şekil 4.15). Siyam sinir ağlarında Adam ve katman bazlı stokastik gradyan inişi teknikleri ile parametre optimizasyonu gerçekleştirilmiş sonuçları karşılaştırılmıştır. Ayrıca veri sayısının genişletilmesinin etkilerini gözlemlemek için uygulama hem veri artırımı hem de veri artırımı olmadan gerçekleştirilmiştir.

4.4.1. Kullanılan veri seti ve veri artırma teknikleri

Uzmanlar tarafından verilen hastalık etiketleri ve bu hastalıkların nasıl gruplandıkları Çizelge 4.18'de gösterilmiştir. Veri seti ve sınıflama çalışmasında kullanılacak hastalık sınıfları organize edilmiş; aynı vücut bölgesinde termal değişiklik göstermesi beklenen hastalıklar ile aynı organları etkileyen veya aynı organlardan etkilenen hastalıklar 7 sınıfa indirgenen veri seti içerisinde bulunmaktadır.



Şekil 4.15. Veri setindeki sınıflar ve yenidoğan sayıları

Termal kameralar kullanılarak elde edilen termogramlar sıcaklık haritalarına ve renkli (RGB) görüntülere dönüştürülebilir. Renkli görüntüler, kullanıcı tarafından alt sınırı yenidoğan vücudundaki en soğuk noktadan daha düşük, üst sınırı ise en sıcak noktadan daha yüksek olacak şekilde belirlenen eşik değere bağlı olarak RGB formatında üretilmiştir. Daha sonra Şekil 3.7’de gösterildiği gibi çeşitli görüntü ön işleme teknikleri ile 105x105 boyutlarındaki gri-seviye görüntülere dönüştürülmüştür.

Veri artırımının etkilerini gözlemlemek için uygulama hem veri artırımı hem de veri artırımı olmadan gerçekleştirilmiştir. Veri artırımında afin dönüşüm teknikleri olan eğme-kaydırma (İng., shear), yakınlaştırma (İng., zoom), döndürme (İng., rotate), kaydırma (İng., shift) kullanılmıştır (Ornek ve Ceylan, 2019).

Veri artırımı, -10 ile 10 derece arasında döndürme, -0.3 ile 0.3 radyan arasında eğme-kaydırma, 0.8 ile 2 katsayı aralığında yakınlaştırma ve ± 5 piksel kaydırma işlemleri ile gerçekleştirilmiştir.

Şekil 4.15’te görüldüğü gibi her bir sınıfta 4 ile 18 arasında yenidoğana ait görüntüler bulunmaktadır. Veri seti 67 yenidoğanın toplam 1340 görüntüsünü içermektedir.

Çizelge 4.18. Derin SSA ve tek atış öğrenme ile sınırlı termal veri kullanılarak yenidoğan hastalıklarının sınıflanması uygulaması için oluşturulan veri seti

Sınıf	No	Yenidoğan	Etiket
Sınıf 1 Kardiyovasküler Hastalıklar (KrdH)	1	Yenidoğan 1	KKH + PDA
	2	Yenidoğan 2	KKH
	3	Yenidoğan 3	HLH
	4	Yenidoğan 4	KKH
	5	Yenidoğan 5	HT + VSD + ASD
	6	Yenidoğan 6	AK
	7	Yenidoğan 7	AK
	8	Yenidoğan 8	KKH + PDA
	9	Yenidoğan 9	KKH + PDA
	10	Yenidoğan 10	HLH
	11	Yenidoğan 11	HT + VSD + ASD
	12	Yenidoğan 12	HT + VSD + ASD
	13	Yenidoğan 13	AK
Sınıf 2 Özofagus Atrezi (ÖA)	1	Yenidoğan 14	ÖA
	2	Yenidoğan 15	ÖA
	3	Yenidoğan 16	ÖA
	4	Yenidoğan 17	ÖA
	5	Yenidoğan 18	ÖA
Sınıf 3 Enfeksiyon Hastalıkları (EnfH)	1	Yenidoğan 19	Adenovirüs
	2	Yenidoğan 20	Pnömoni
	3	Yenidoğan 21	Adenovirüs
	4	Yenidoğan 22	Adenovirüs
Sınıf 4 İntestinal Anomaliler (İA)	1	Yenidoğan 23	IAtr
	2	Yenidoğan 24	IO
	3	Yenidoğan 25	IAtr
	4	Yenidoğan 26	IAtr
Sınıf 5 Nekrotizan Enterokolit (NEC)	1	Yenidoğan 27	NEC
	2	Yenidoğan 28	NEC
	3	Yenidoğan 29	NEC
	4	Yenidoğan 30	NEC
	5	Yenidoğan 31	NEC
	6	Yenidoğan 32	NEC

Sınıf 6 Prematürite (PRM)	1	Yenidoğan 33	Prm
	2	Yenidoğan 34	Prm
	3	Yenidoğan 35	Prm
	4	Yenidoğan 36	Prm
	5	Yenidoğan 37	Prm
	6	Yenidoğan 38	Prm
	7	Yenidoğan 39	Prm
	8	Yenidoğan 40	Prm
	9	Yenidoğan 41	Prm
	10	Yenidoğan 42	Prm
	11	Yenidoğan 43	Prm
	12	Yenidoğan 44	Prm
	13	Yenidoğan 45	Prm
	14	Yenidoğan 46	Prm
	15	Yenidoğan 47	Prm
	16	Yenidoğan 48	Prm
	17	Yenidoğan 49	Prm
Sınıf 7 Pulmoner Anomaliler (PA)	1	Yenidoğan 50	TTN
	2	Yenidoğan 51	TTN
	3	Yenidoğan 52	RDS
	4	Yenidoğan 53	RDS
	5	Yenidoğan 54	TTN
	6	Yenidoğan 55	TTN
	7	Yenidoğan 56	RDS
	8	Yenidoğan 57	RDS
	9	Yenidoğan 58	RDS
	10	Yenidoğan 59	RDS
	11	Yenidoğan 60	RDS
	12	Yenidoğan 61	RDS
	13	Yenidoğan 62	RDS
	14	Yenidoğan 63	RDS
	15	Yenidoğan 64	RDS
	16	Yenidoğan 65	RDS
	17	Yenidoğan 66	RDS
	18	Yenidoğan 67	RDS

4.4.2. SSA ile tek atış öğrenme uygulaması

Tek atış öğrenme yaklaşımında veri seti arka plan ve değerlendirme verileri olmak üzere iki ayrı kümeye ayrılmıştır. Derin SSA modeli arka plan seti ile eğitilirken hiperparametre ve özellikler bu set ile öğrenilmektedir. Modelin eğitiminde kullanılmayan (hiç görülmemiş), tamamen farklı sınıflardan görüntüler içeren değerlendirme seti ile modelin başarımı test edilmektedir. Uygulamada farklı sınıfların arka plan ve değerlendirme setlerinde bulunması halinde vereceği sonuçları gözlemlemek için farklı varyasyonlar kullanılmıştır. Bu varyasyonlar 2 ana yaklaşım altında ele alınmıştır:

1. Yaklaşım: Tüm veri setindeki 7 sınıfın 3'ü değerlendirme 4'ü arka plan verisi olarak kullanılmıştır.

Bu yaklaşımda 7 sınıfın her biri üçer kez değerlendirme veri setine yerleştirilmiş ve sınıflanmıştır.

2. Yaklaşım: Tüm veri setindeki 7 sınıfın 2'si değerlendirme 5'i ise arka plan verisi olarak kullanılmıştır.

Bu yaklaşımda da tüm sınıflar ikişer kez değerlendirme veri setine yerleştirilmiştir.

Her iki yaklaşımda değerlendirme veri setine alınan veri sınıfı ayrımı bir döngü halinde yapılmış ve Çizelge 4.19 ve Çizelge 4.20'de gösterilmiştir.

Çizelge 4.19. 1. yaklaşım için arka plan ve değerlendirme veri setlerinin ayrılması.

3 Sınıflı Değerlendirme Yaklaşımı (1. Yaklaşım)									
	1. uygulama	2. uygulama	3. uygulama	4. uygulama	5. uygulama	6. uygulama	7. uygulama		
Değerlendirme Veri Seti	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM	7 PA		
	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM	7 PA	1 KrdH		
	3 EnfH	4 İA	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA		
Arka Plan Veri Seti	4 İA	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH		
	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA		
	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC		
	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM		


Çizelge 4.20. 2. yaklaşım için arka plan ve değerlendirme veri setlerinin ayrılması.

2 Sınıflı Değerlendirme Yaklaşımı (2. Yaklaşım)									
	1. uygulama	2. uygulama	3. uygulama	4. uygulama	5. uygulama	6. uygulama	7. uygulama		
Değerlendirme Veri Seti	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM	7 PA		
	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM	7 PA	1 KrdH		
Arka Plan Veri Seti	3 EnfH	4 İA	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA		
	4 İA	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH		
	5 NEC	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA		
	6 PRM	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC		
	7 PA	1 KrdH	2 ÖA	3 EnfH	4 İA	5 NEC	6 PRM		

Uygulamada değerlendirme setindeki performansı ölçmek için 20-yollu tek atış görevi kullanılmıştır. Her bir örnek girdi için 40 kez 20-yollu sınıflama görevi gerçekleştirilmiş ve 2 değerlendirme sınıfı için 80, 3 değerlendirme sınıfı için 120 görev tamamlanmıştır. Veri setinde bulunan 7 sınıfın 2'si değerlendirme setinde ise 5'i arka plan setinde yer almıştır.

4.4.3. Derin SSA modeli

Derin SSA modeli, farklı filtre boyutlarında ve “kaydırma” değeri 1 olan bir dizi konvolüsyon katmanını içermektedir. Konvolüsyon katmanlarında filtre sayısı performansı optimize etmek amacıyla 16'nın katları olarak seçilmiştir. Her iki konvolüsyon katmanını arasına 2 x 2'lik çerçeveler kullanan maksimum havuzlama katmanları eklenmiştir. Bu katmanlara “kaydırma” değeri 2 olarak atanmıştır. Derin Siyam sinir ağı modelinin ikiz ağ yapısı Şekil 4.16'da gösterildiği gibidir. Ağırlık ve hiperparametre paylaşan ikiz ağların son konvolüsyon katmanlarındaki nöronlar 4096 x 1 boyutlarındaki vektörler halinde düzleştirilir. Bu vektörler sigmoid aktivasyon fonksiyonu kullanan tam-bağlı ağ katmanına aktarılır. Sigmoid fonksiyonu 1 ile 0 (aynı sınıf veya farklı sınıf) arasında bir değer üretir.



Şekil 4.16. Derin SSA'nın ikiz ağ yapısı ve sistemin genel blok gösterimi

Bu çalışmada, ağa giren görüntülerin aynı sınıftan olup olmadıklarını tespit etmek için ($0 < P < 1$) bir sigmoid aktivasyon fonksiyonuyla kombine edilen, ikiz ağların özellik vektörleri h_1 ve h_2 arasındaki ağırlıklı L1 mesafesine bakılmıştır.

$$P = \sigma(\sum_j a_j |h_{1,L-1}^j - h_{2,L-1}^j|) \quad (4.10)$$

Ağın benzerlik skoru (P), Eşitlik 4.10'da verilmiştir. Burada σ , sigmoid aktivasyon fonksiyonunu, a_j ise model tarafından eğitim sırasında öğrenilen ve eleman bazında mesafenin önemini ağırlıklandıran parametreleri ifade etmektedir.

4.4.4. Optimizasyon algoritmaları

Uygulamada optimizasyon algoritması olarak katman bazlı stokastik gradyien inişi (kb-SGİ) ve Adam optimizasyon algoritmaları kullanılmış ve her iki yöntemin sonuçları karşılaştırmalı olarak sunulmuştur.

Kb-SGİ algoritmasında ağın tüm katmanlarında sabit bir öğrenme oranı kullanmak yerine katman-bazlı öğrenme oranı uygulanmıştır. Öğrenme oranı başlangıç değeri, uygulanan farklı yaklaşımlar için optimizasyon algoritmasının öğrenme hızı ve veri seti boyutunun değişimi gözetilerek deneysel olarak farklı değerlerde verilmiş ve farklı epok sayılarında %1 azaltılmıştır. Verilen öğrenme oranı başlangıç değerleri ve azaltılma sıklığı Çizelge 4.21'de gösterilmiştir. Momentum değeri ise başlangıçta her katman için 0.5 olarak verilmiş ve her epokta 0.01'lik artışlarla 0.9'a kadar artırılmıştır.


Çizelge 4.21. Öğrenme oranı başlangıç değerleri ve epok sayısına bağlı değişimi.

Optimizasyon Algoritması	Veri Artırımı	Öğrenme Oranı başlangıç değeri	Öğrenme oranının azaltılması
kb-SGİ	Var (kb-SGİ1)	0.001	Her 200 epokta bir %1
	Yok (kb-SGİ2)	0.001	Her 100 epokta bir %1
Adam	Var (Adam1)	0.00001	Her 50 epokta %1
	Yok (Adam2)	0.00001	Her 10 epokta %1

4.4.5. Uygulama sonuçları

Bu çalışmada, yenidoğan yoğun bakım ünitesinde tedavi edilen bebeklerin hastalıklarını tespit etmek üzere bir ön tanı sistemi geliştirilmiştir. Bu amaçla sınırlı termal görüntü veri tabanı kullanılmış ve ağ modelinin eğitimde hiç görmediği sınıfları belirlemek için tek-atış öğrenme görevleri tanımlanmıştır. Her biri 4 ila 18 arasında yenidoğana ait görüntü içeren veri seti SSA modeli ile farklı optimizasyon teknikleri ve veri sayısı yaklaşımları kullanılarak sınıflanmıştır.

Uygulanan derin siyam sinir ağları ile tek-atış öğrenme yaklaşımına ilişkin genel gösterim Şekil 4.17’de sunulmuştur.

**Şekil 4.17.** Derin SSA ile yenidoğan hastalıklarının sınıflanması için uygulama yönergesi blok gösterimi

Uygulama sonuçları arka plan ve değerlendirme setlerine ayrılan veri setleri için değerlendirme setine 2 ve 3 sınıfın yerleştirilme durumlarına göre iki yaklaşım altında incelenmiştir. Bu iki veri seti dağılımı yaklaşımına ek olarak kb-SGİ ve Adam optimizasyon tekniklerinin, veri artırımı ve veri artırımsız olarak uygulanmasıyla elde edilen sonuçlar sınıf bazlı ve yöntem bazlı olarak iki ayrı çizelge halinde sunulmuştur. Çizelge 4.22’de 4 sınıfın arka plan, 3 sınıfın değerlendirme setine alınmasıyla gerçekleştirilen, Çizelge 4.23’te ise 5 sınıfın arka plan, 2 sınıfın değerlendirme setine ayrıldığı uygulama sonuçları gösterilmektedir. Her iki çizelgenin son satırında optimizasyon algoritmaları bazlı sınıflama sonuçları verilmektedir. Optimizasyon algoritmalarının ortalama doğrulukları incelendiğinde kb-SGİ optimizasyonu kullanıldığında daha yüksek doğruluk elde edildiği görülmektedir.

Çizelge 4.22. 4 sınıf arka plan, 3 sınıf değerlendirme veri setine ayrıldığında elde edilen doğruluk değerleri (1. Yaklaşım)

	kb-SGİ 1 (Veri artırımsız)		kb-SGİ 2 (Veri artırımı)		Adam 1 (Veri artırımsız)		Adam 2 (Veri artırımı)	
	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)
KrdH	95.00		90.00		77.50		87.50	
ÖA	100.00	97.50	95.00	95.00	85.00	86.67	85.00	90.83
EnfH	97.50		100.00		97.50		100.00	
ÖA	92.50		70.00		80.00		90.00	
EnfH	100.00	97.50	97.50	85.83	100.00	90.83	97.50	95.83
İA	100.00		90.00		92.50		100.00	
EnfH	97.50		100.00		97.50		100.00	
İA	97.50	97.50	100.00	95.83	92.50	89.17	92.50	95.00
NEC	97.50		87.50		77.50		92.50	
İA	100.00		97.50		90.00		87.50	
NEC	95.00	86.67	90.00	90.83	87.50	76.67	82.50	77.50
PRM	65.00		85.00		52.50		62.50	
NEC	90.00		95.00		87.50		100.00	
PRM	72.50	84.17	82.50	90.83	82.50	77.50	77.50	90.00
PA	90.00		95.00		62.50		92.50	
PRM	80.00		85.00		92.50		95.00	
PA	92.50	85.00	85.00	85.83	85.00	85.00	77.50	86.67
KrdH	82.50		87.50		77.50		87.50	
PA	82.50		85.00		60.00		77.50	
KrdH	80.00	82.50	90.00	91.67	67.50	65.83	65.00	77.50
ÖA	85.00		100.00		70.00		90.00	
Algoritma Bazlı Doğruluk	%90.12		%90.83		%81.67		%87.62	

Çizelge 4.23. 5 sınıf arka plan, 2 sınıf değerlendirme veri setine ayrıldığında elde edilen doğruluk değerleri (2. Yaklaşım)

	kb-SGİ 1 (Veri artırısız)		kb-SGİ 2 (Veri artırılı)		Adam 1 (Veri artırısız)		Adam 2 (Veri artırılı)	
	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)	Doğruluk (%)	Ort. Doğruluk (%)
KrdH	85.00	92.50	90.00	95.00	92.50	88.75	77.50	80.00
ÖA	100.00		100.00		85.00		82.50	
ÖA	90.00	95.00	100.00	100.00	97.50	95.00	97.50	93.75
EnfH	100.00		100.00		92.50		90.00	
EnfH	100.00	98.75	100.00	98.75	97.50	90.00	92.50	95.00
İA	97.50		97.50		82.50		97.50	
İA	97.50	96.25	97.50	91.25	95.00	90.00	92.50	88.75
NEC	95.00		85.00		85.00		85.00	
NEC	90.00	87.50	97.50	93.75	97.50	93.75	97.50	90.00
PRM	85.00		90.00		90.00		82.50	
PRM	90.00	90.00	95.00	91.25	85.00	81.25	70.00	78.75
PA	90.00		87.50		77.50		87.50	
PA	87.50	82.50	90.00	77.50	77.50	71.25	92.50	85.00
KrdH	77.50		65.00		65.00		77.50	
Algoritma Bazlı Doğruluk	%91.79		%92.50		%87.14		%87.32	

Elde edilen sınıflama sonuçlarını sınıf bazlı olarak değerlendirmek için Çizelge 4.24 ve Çizelge 4.25 verilmiştir.


Çizelge 4.24. Elde edilen sınıf bazlı doğruluk değerleri (1. Yaklaşım)

	1. Yaklaşım (3 sınıf değerlendirme – 4 sınıf arka plan)			
Değerlendirilen Sınıflar	kb-SGİ 1 (Veri artırısız) (%)	kb-SGİ 2 (Veri artırılı) (%)	Adam 1 (Veri artırısız) (%)	Adam 2 (Veri artırılı) (%)
KrdH	85.83	89.17	74.17	80.00
ÖA	92.50	88.33	78.33	88.33
EnfH	98.33	99.17	98.33	99.17
İA	99.17	95.83	91.67	93.33
NEC	94.17	90.83	84.17	91.67
PRM	72.50	84.17	75.83	78.33
PA	88.33	88.33	69.17	82.50
Ortalama	90.12	90.83	81.67	87.62


Çizelge 4.25. Elde edilen sınıf bazlı doğruluk değerleri (2. Yaklaşım)

Değerlendirilen Sınıflar	2.Yaklaşım (2 sınıf değerlendirme – 5 sınıf arka plan)			
	kb-SGİ 1 (Veri artırısız) (%)	kb-SGİ 2 (Veri artırılı) (%)	Adam 1 (Veri artırısız) (%)	Adam 2 (Veri artırılı) (%)
KrdH	81.25	77.50	78.75	77.50
ÖA	95.00	100.00	91.25	90.00
EnfH	100.00	100.00	95.00	91.25
İA	97.50	97.50	88.75	95.00
NEC	92.50	91.25	91.25	91.25
PRM	87.50	92.50	87.50	76.25
PA	88.75	88.75	77.50	90.00
Ortalama	91.79	92.50	87.14	87.32

Derin SSA ve tek atış öğrenme ile sınırlı termal veri seti kullanarak yenidoğan hastalıklarının sınıflanması uygulamasında elde edilen sınıf bazlı sınıflama başarımları grafikleri Şekil 4.18 ve Şekil 4.19’da verilmiştir.



Şekil 4.17. 1. Yaklaşım için sınıf bazlı (%) doğruluk grafiği



Şekil 4.18. 2. Yaklaşım için sınıf bazlı (%) doğruluk grafiği

Bu uygulamada veri sayısının az, sınıflar arası veri dengesinin bozuk ve sınıf sayısının fazla olduğu “yenidoğan yoğun bakım ünitesinde karşılaşılan hastalıkların sınırlı veri seti ile sınıflanması” problemine yönelik derin SSA ile tek atış öğrenme yaklaşımı kullanılmıştır. Değerlendirme ve arka plan veri setleri oluşturulurken bazı yenidoğan hastalıklarının, etkiledikleri vücut bölgelerinin birbirine yakın olması nedeniyle algoritma tarafından karıştırılacağı öngörülerek değerlendirme setlerine bu hastalıklar karşılaştırılacak şekilde yerleştirilmiştir. Bu sayede önerilen yöntemin sınıflama başarımını zor koşullar altında test etmek için birbirine yakın asimetri göstermesi beklenen hastalık gruplarını sınıflama görevleri tanımlanmıştır. Örnek vermek gerekirse her iki değerlendirme seti oluşturma yönteminde kalp ve akciğerlere yakın cilt yüzeyinde değişiklik göstermesi beklenen kardiyovasküler hastalıklar, özofagus atrezi ve pulmoner anomaliler ile bağırsakları ilgilendiren NEC ve intestinal anomaliler aynı değerlendirme setlerine yerleştirilmiştir.

Sonuçlar, kardiyovasküler hastalıklar, özofagus atrezi ve pulmoner hastalıkların ortalama %91.7, kardiyovasküler hastalıklar ve özofagus atrezinin ortalama %95, NEC ve diğer intestinal anomalilerin ise %96.25 doğrulukla birbirinden ayırt edilebildiğini ortaya koymuştur. Hastalık bazında en yüksek doğruluk enfeksiyon hastalıklarında elde edilmiştir. 3 sınıfın değerlendirme setine alındığı 1. Yöntemde %99.17, 2 sınıfın değerlendirme setine alındığı 2. yöntemde ise %100 doğrulukla sınıflanmıştır.



5. SONUÇLAR VE ÖNERİLER

Yenidoğanın dış ortama karşı hassas olması nedeniyle büyük bir termogram veritabanı oluşturmak zordur. YYBÜ’nde bazı hastalıklara sıkça rastlanırken, bazı hastalıklar nadiren görülür ve nadir hastalıklar ölümcül olabilir. Bu nedenle nadir hastalıkları tespit etmek hayati önem taşır. Bu çalışmada, sınırlı (az sayıda ve dengesiz) yenidoğan termogramı veri seti kullanarak hastalıkları sınıflayan yaklaşımlar geliştirilmiştir.

5.1. Sonuçlar

Gerçekleştirilen çalışma neticesinde, kullanılan derin öğrenme yöntemleri ESA ve SSA ile termal görüntüler sınıflanırken, parlaklık değiştirme, renk değiştirme, karşıtlık değiştirme ve keskinleştirme gibi veri artırma tekniklerinin kullanımının sınıflama başarımını artırdığı görülmüştür.

Tez çalışmasında gerçekleştirilen uygulamalar önceki bölümde ele alınmış ve elde edilen nicel sonuçlar çizelge ve grafikler üzerinde gösterilmiştir (Bölüm 4).

Bu uygulamalardan ilkinde tam bağlı ağ katmanında YSA ve DVM kullanılan ESA modelleri ile ‘abdominal & renal hastalıklar’, ‘kardiyovasküler hastalıklar’ ve ‘pulmoner anomaliler’ 44 yenidoğana ait termogramlar kullanılarak sınıflanmıştır. Yaklaşım I (her yenidoğandan 5’er tane olmak üzere 220 görüntü) ve yaklaşım II (her yenidoğandan 20’şer görüntü olmak üzere 880 görüntü) birbirine yakın değerlendirme sonuçları verse de 880 görüntü kullanıldığında 220 görüntüye göre daha yüksek sınıflama başarımı elde edilmiştir. Özgüllük ve doğruluk metrikleri bazı sınıflar için %60-65 aralığında bazı sınıflar için ise %80-85 aralığında değer vermiştir. ESA yapısı içerisinde yer alan tam bağlı ağ katmanı yöntemlerine göre sonuçlar incelendiğinde YSA kullanıldığında elde edilen sınıflama başarımının (%74.1), DVM ile karşılaştırıldığında üstün olduğu görülmüştür. Daha sonra yapılacak çalışmaların temelini oluşturacağı için bu uygulamada ESA tercih edilmiştir. Bu çalışma ile büyük veri setlerinde başarılı sonuçlar veren ESA’nın sınırlı veri setlerinde göstereceği performans değerlendirilmiştir.

İkinci uygulamada, altı farklı eğitim-test veri dağılımı yaklaşımı uygulanan yenidoğan termogram veri seti kullanılarak ESA ile 4 farklı hastalık sınıfının tespit edilmesi üzerine sınıflama gerçekleştirilmiştir. Eğitim-test veri dağılımı yaklaşımları uygulanmasının nedeni sınırlı termal verinin farklı veri yaklaşımları altında vereceği

sınıflama başarımını gözlemlemektir. Altı yaklaşımın bazılarında veri artırımı yapılırken bazılarında ham veri seti kullanılmıştır. En yüksek doğruluk değeri (%94.55) 44 yenidoğandan alınan 880 görüntü bulunan veri setindeki her bebeğe ait 20 görüntüden 15'er tanesinin modelin eğitiminde kalan 5'er görüntünün test verisi olarak kullanılmasıyla elde edilmiştir. Bir başka yaklaşımda modelin hiç görmediği örneklerle test edilebilmesi için eğitim ve test setleri tamamen ayrılmıştır. Veri artırımı ile eğitim setindeki 600 görüntü 2400'e (toplam 2680 görüntü) çıkarıldığında %89 sınıflama doğruluğu sağlanmıştır. Bu yaklaşımda kontrast değiştirme, parlaklık artırma ve keskinleştirme yapılarak sınıflama başarımının yükseldiği gözlemlenmiştir. Eğitim setindeki görüntü sayısını 2400'den 4800'e çıkarmak için RGB görüntülerin gri-seviye eşdeğerleri eklenmiş ve %88.79 doğruluk değeri ortaya çıkmıştır. Bu uygulamada, gri-seviye eşdeğerleri ile veri sayısı artırıldığında, kontrast değiştirme, parlaklık artırma ve keskinleştirme kullanılan yaklaşım ile aynı etkiye sahip olmadığı sonucuna varılabilir. Uygulamanın bir başka yaklaşımında sınıflar arası veri dengesizliğini artırmak için dört sınıftan üçünde veri artırımı yapıp bir sınıfın veri sayısı sabit tutulduğunda %69.29 doğruluk elde edilmiştir.

Yenidoğanlarda pulmoner anomalilerin ESA ile belirlenmesi uygulamasında solunum sistemiyle ilgili doğuştan ya da sonradan gelişen hastalıkların belirlenmesi ve diğer yenidoğan hastalıklarından ayırt edilmesi sağlanmıştır. Çalışmanın ilk aşamasında, 34 yenidoğanın 680 görüntüsü kullanılmış, ikinci aşamada ise veri sayısı farklı veri artırma teknikleri ile 2060'a yükseltilmiştir. Orijinal veri kümesi sonuçları %80 duyarlılık, %88 özgüllük, %85 doğruluk olarak elde edilmiştir. Termal görüntülerin sayısı 680'den 2060'a yükseltildiğinde yöntemin başarımı artmış ve doğruluk %91, özgüllük %100 olarak hesaplanmıştır. Sonuçlar, veri artışı ile daha iyi sonuçlar alınmasının mümkün olduğunu ve kullanılan modelin termal görüntülerden yenidoğan hastalıklarının tespiti için uygun olduğunu göstermiştir.

Siyam sinir ağları ve tek atış öğrenme ile sınırlı termal veri seti kullanarak yenidoğan hastalıklarının sınıflanması başlıklı son uygulamada ise veri sayısının az, sınıflar arası veri dengesinin bozuk ve sınıf sayısının fazla olduğu durumda her birinde 4 ila 18 yenidoğan görüntüsü bulunan yedi sınıfın birbirinden ayırt edilmesi sağlanmıştır. Sonuçlar incelendiğinde, enfeksiyon hastalıklarının sınıflanmasında; %100, intestinal anomalilerin sınıflanmasında da %99.17 doğruluk elde edildiği görülmektedir. Bazı yenidoğan hastalıklarının, etkiledikleri vücut bölgelerinin birbirine yakın olması nedeniyle derin öğrenme modelleri tarafından ayırt edilmesinin zorluğu varsayımı ile

değerlendirme setlerine bu hastalıklar karşılaştırılacak şekilde yerleştirilmiştir. 3 sınıflı ve 2 sınıflı değerlendirme seti yaklaşımlarında kalp ve akciğerlere yakın cilt yüzeyinde değişiklik göstermesi beklenen kardiyovasküler hastalıklar, özofagus atrezi ve pulmoner anomaliler (1. yaklaşım) ile bağırsakları ilgilendiren NEC ve intestinal anomaliler (2. yaklaşım) karşılaştırılacak şekilde yerleştirilmiştir. Sonuçlar, kardiyovasküler hastalıklar, özofagus atrezi ve pulmoner hastalıkların ortalama %91.7, kardiyovasküler hastalıklar ve özofagus atrezinin ortalama 95%, NEC ve diğer intestinal anomalilerin ise %96.25 doğrulukla birbirinden ayırt edilebildiğini ortaya koymuştur.

Çizelge 4.26'da yenidoğan termal görüntüleme üzerine daha önce yapılan çalışmalar ile bu tez kapsamında gerçekleştirilen uygulamalar karşılaştırılmıştır.



Çizelge 4.26. Tez çalışmasında sunulan uygulamaların önceki çalışmalarla performanslarının karşılaştırması

Araştırma	Amaç ve Kapsam	Çıktılar	Veri Seti Boyutu	Veri Artırımı	Sınıflama	İkili / Çok sınıflı
(Oya ve ark., 1997)	Yenidoğanların yağ dokusunda NST kapsamını ölçmek ve doğumdaki oksijen seviyelerinin etkisini incelemek	Sonuçlar, NST'nin doğumdan hemen sonra başladığı ve vücut ısısının yükselmesine katkıda bulunduğu sonucunu desteklemektedir.	15 yenidoğan	Yok	Yok	-
(Christidis ve ark., 2003)	Termografi kullanımı ile birçok klinik senaryo altında vücut yüzey sıcaklığı gözlenmiştir.	Doğumdan hemen sonra yüzey sıcaklığı düzenli bir dağılım göstermiştir. Doğumdan kısa bir süre sonra periferik bölgeler soğumuş, gövdede sıcaklık korunmuştur.	42 yenidoğan	Yok	Yok	-
(Abbas ve Leonhardt, 2008)	Yenidoğan cildinin termal modelinin BBA hibrit model algoritmasına göre sınıflanması	BBA ile yenidoğan baş bölgesinde çevresel koşullardan bağımsız sıcaklık değişimi gözlenmiştir.	12 yenidoğan	Gürültü giderme	Var	İkili
(Rice ve ark., 2010)	Aşırı düşük doğum ağırlıklı (ADDA) bebeklerde abdominal sıcaklık dağılımı ile NEC arasında ilişki olup olmadığının tespiti.	ADDA bebek termografisi, termoregülasyon çalışması için yararlıdır ve NEC'de bölgesel perfüzyonun rolü hakkında yeni bilgiler verdiği kanıtlanmıştır.	13 ADDA yenidoğan	Yok	Yok	-
(Herry ve ark., 2011)	NEC hastalığının termografi ile belirlenmesi.	Termal görüntülemenin, NEC'i erken teşhis etmeye yardımcı olabilecek ek bilgiler sağladığı gösterilmiştir.	48 sağlıklı, 11 NEC'li yenidoğan	Yok	Var Doğruluk: >%90	İkili
(Abbas ve ark., 2012)	Yenidoğan termogramlarının etkinliğini ve güvenilirliğini farklı klinik senaryolar altında test etmek.	Değişken tolerans değerleri olmasına rağmen, tatmin edici sonuçlar elde edilmiştir.	12 prematüre yenidoğan	Yok	Yok	-

(Frize ve ark., 2013)	Yenidoğanlarda NEC hastalığını belirlemek için termal görüntülemeye dayalı analiz yöntemi geliştirmek.	NEC'li bebeklerde yukarıdan aşağıya bölge sıcaklıkları önemli ölçüde farklılık gösterirken, sağlıklı bebeklerde düzenli bir dağılım tespit edilmiştir.	20 sağlıklı, 9 NEC'li yenidoğan	Yok	Karar Ağacı Özgüllük: %90 +/-12 Duyarlılık: %78 +/-12	İkili
(Heimann ve ark., 2013)	Isı düzenlemesini ve dağılımını incelemek için birden fazla vücut bölgesinde IRT ile farklı pozisyonları kullanarak cilt sıcaklığını değerlendirmek.	IRT ile, çok sayıda merkezi ve periferik vücut bölgesinde inkübatörde farklı pozisyonlarda cilt sıcaklığını değerlendirmek mümkün olmuştur.	10 yenidoğan	Yok	Yok	-
(Knobel-Dail ve ark., 2017)	Prematüre yenidoğanların termal görüntüleme ile sıcaklık değişimlerini lokal olarak tespit etmek.	Termal görüntüleme ile yenidoğan cildinin farklı bölgelerindeki sıcaklık dağılımlarını yüksek doğrulukla belirlenmiştir.	31 prematüre yenidoğan	Yok	Yok	-
(Ornek ve ark., 2019)	Derin öğrenme yöntemleri ile yenidoğan hasta-sağlıklı sınıflaması.	Veri artırımı yapıldığında daha iyi sonuçlar elde edildiği gözlenmiştir.	19 sağlıklı, 19 hasta yenidoğan	Parlaklık geliştirme, kontrast ve çözünürlük değiştirme, renk dönüştürme, gürültü ekleme	Duyarlılık: %99.7 Özgüllük: %99.43 Doğruluk: %99.58	İkili
(Savasci ve ark., 2019)	ÇÇA – YSA Hibrit modeli ile yenidoğan hasta-sağlıklı sınıflaması.	Geleneksel dalgacık dönüşümünün başarımının, curvelet ve contourlet dönüşümlerinin başarımından daha üstün olduğu görülmüştür.	19 sağlıklı, 19 hasta yenidoğan	Yok	Doğruluk: %98.42 Duyarlılık: %100 Özgüllük: %96.84	İkili
(Ornek ve ark., 2020)	Makine öğrenmesi yöntemleri ile yenidoğan hasta-sağlıklı sınıflaması.	Termal haritalardan yerel ikili desen ve hızlı korelasyon tabanlı filtre yaklaşımları ile özellik seçme uygulamış, KA, YSA, LR ve RO algoritmaları ile hasta-sağlıklı sınıflaması gerçekleştirilmiştir	20 sağlıklı, 20 hasta yenidoğan	Yok	Doğruluk: %92	İkili

Tez çalışmasında	Sınırlı yenidoğan termogramı verisi kullanarak derin öğrenme ile hastalıkların sınıflaması.	Tam bağlı ağ katmanında YSA ve DVM kullanılan iki ayrı yöntemle sınırlı veriden kardiyovasküler hastalıklar, pulmoner anomaliler ve abdominal&renal hastalıklar sınıflanmıştır.	10 KrdH, 16 PA, 8 ARH, 10 Prematüre (sağlıklı) olmak üzere 44 yenidoğan	Ölçeklendirme, eğme kaydırma, yakınlaştırma ve yatay döndürme	Doğruluk: %83 Özgüllük: %91	Çok sınıflı
Tez çalışmasında	Sınırlı yenidoğan termogramı verisi kullanarak derin öğrenme ile hastalıkların çok sınıflı olarak sınıflaması.	Veri artırımı teknikleri ile ESA kullanılarak 4 farklı yenidoğan hastalığını tespit edebilen sınıflama çalışması yapılmıştır	10 KrdH, 16 PA, 8 ARH, 10 Prematüre (sağlıklı) olmak üzere 44 yenidoğan	Keskinleştirme, kontrast değiştirme, parlaklık geliştirme, gri-seviye dönüşümü	Doğruluk: %94 Duyarlılık: %94.88 Kesinlik: %94.4	Çok sınıflı
Tez çalışmasında	Pulmoner Anomalilerin sınırlı termogramı verisi ve derin öğrenme ile belirlenmesi.	Pulmoner anomalilerin, az sayıda örnek ile diğer yenidoğan hastalıklarının bulunduğu veri setinde ayırt edilmesi.	16 PA, 18 diğer hastalıklar olmak üzere 34 yenidoğan	Keskinleştirme, kontrast değiştirme, parlaklık geliştirme.	Doğruluk: %91 Duyarlılık: %100 Kesinlik: %86	İki sınıflı
Tez çalışmasında	Siyam sinir ağları ile tek atış öğrenme yöntemini kullanarak her sınıftan sadece birkaç veri ile yenidoğan hastalıklarının sınıflanması.	SSA ile tek atış öğrenme yaklaşımının veri artırımı ile birlikte kullanıldığında yenidoğan hastalıklarının sınıflamada başarılı olduğu görülmüştür.	13 KrdH, 5 ÖA, 4 EnfH, 4 İA, 6 NEC, 17 PRM, 18 PA olmak üzere 7 farklı sınıftan 67 yenidoğan	Döndürme, eğme kaydırma, yakınlaştırma, kaydırma.	EnfH'nı belirlemede %100 KrdH, ÖA, PA hastalıklarını ayırt etmede %91.7, KrdH ve ÖA hastalıklarını birbirinden ayırmada %95, NEC ve İA'da ise %96.25 doğruluk.	Çok sınıflı

Termal görüntülemenin yenidoğan hastalıklarına yönelik ilk çalışmaları genellikle termal verinin uzman tarafından yorumlanmasına dayalıdır. Makine öğrenmesi yöntemlerine olan ilginin artması ile son birkaç yılda çalışmalar otomatik sınıflama eksenine kaymıştır. Ancak yapılan çalışmaların birçoğunun, spesifik olarak bir hastalığın tespiti veya doğrudan hasta-sağlıklı sınıflaması üzerine olduğu görülmektedir. Tez kapsamında önerilen yöntemler ile hasta-sağlıklı sınıflamanın ötesine geçilerek az veri bulunan hastalıkları da ayrı ayrı tespit edebilen çok sınıflı sınıflama uygulamaları gerçekleştirilmiştir. Özellikle aynı vücut bölgesi üzerinde termal değişiklik göstermesi beklenen hastalıkların yüksek başarımla sınıflanması önerilen metotların isabetli olduğunu göstermektedir.

5.2. Öneriler

Yenidoğanın sağlık durumunun izlenmesi ve tedavi sürecine olabildiğince erken başlanması ölüm oranlarını düşürecekse bu konudaki tüm çalışmalar değerlidir. Yenidoğan sağlık durumuna ilişkin ilk görüş, çocuk doktorları tarafından rutin muayeneler ve klinik değerlerin gözlemlenmesi ve bulguların incelenmesi sonucunda oluşur (Apgar, 2015). Ancak, önemli bir hastalık belirtisi ortaya çıkarsa ek tedavi veya tıbbi görüntüleme yöntemlerine başvurulmaktadır. Yaygın olarak kullanılan görüntüleme tekniklerinin bazı zararlı etkileri, yenidoğanların sağlık durumunun kontrol edilmesini zorlaştırmaktadır (Taylor, 2008). Ek olarak, yenidoğan yoğun bakım ünitelerinde tedavi gören bebeklerin önemli bir bağıışıklığı olmadığı için özenli bakım gereklidir. Bu nedenle bu bebeklerin bağlı oldukları cihazlardan ve inkübatörlerden ayrılmaması gerekir. Termal görüntüleme, cilt sıcaklığıyla ilgili fizyolojik fonksiyonları analiz etmek için noninvaziv, iyonize olmayan ve temassız bir yöntem olarak öne çıkmaktadır. Termal görüntülemenin bu önemli özelliklerinden dolayı özellikle termal görüntülerin hızlı bir şekilde değerlendirilebileceği düşünüldüğünde doğum akabinde belirli periyotlarla termal görüntüleme yapılması ve yenidoğan yoğun bakım ünitelerinde kullanımı önerilmektedir. Belirli bir vücut bölgesine odaklanma ya da tüm vucüt taraması ile termal asimetrisinin tespiti gibi avantajları bu öneriyi desteklemektedir.

Uygulanan yöntemle yenidoğanlar inkübatörlerden ve bağlı oldukları cihazlardan ayrılmadan, 1 dakika gibi kısa bir sürede 100 termal görüntü kaydedilebilmektedir. Sınıflama için gerekli veri sayısını artırmak ve görüntü çeşitliliğini sağlamak için, bebeğin pozisyonu değiştirilerek ve kamera hareket ettirilerek farklı açılardan ve farklı mesafelerden görüntü alınmalıdır. Böylece hem mevcut makine öğrenimi ve derin öğrenme yöntemleri ile analiz hem de ileride geliştirilecek yeni yöntemler ile analiz için hazır veri setleri oluşmuş olacaktır. Ayrıca bu hareket esnasında oluşacak artefaktları engellemek için sarsıntı sönmüleyici kamera dengeleme fikstürlerinin kullanımı önerilmektedir.

Derin öğrenme yöntemlerinden evrişimli sinir ağları ile sınıflama gerçekleştirileceğinde, konvolüsyon, havuzlama ve tam bağlı katman seçimine dikkat edilmelidir. Konvolüsyon ve havuzlama katmanlarından her biri eklenmeden önce, oluşacak özellik haritasının boyutu hesaplanmalıdır. Aktivasyon fonksiyonu ve hiperparametre seçimi de sınıflama başarımında diğer önemli kriterlerdir.

Derin SSA ile tek atış öğrenme yaklaşımı, çok sayıda sınıfın bulunduğu, veri sayısının yetersiz ve dengesiz olduğu yenidoğan yoğun bakım ünitesinde karşılaşılan hastalıkları sınıflama sorununa çözüm olarak kullanılmıştır. Sınıflama aşamasında mesafe metriği olarak mutlak hata yerine kullanılabilecek Öklid mesafesi, kosinüs mesafesi gibi diğer kayıp fonksiyonlarının incelenmesi etkili olabilir.

Ayrıca bu çalışmada kullanılan geleneksel veri artırma tekniklerinin sayı ve çeşitliliğinin artırılması sınıflama başarımını yükseltebilir. Sentetik veri üretiminde kullanılan çekişmeli üretici ağlar gibi gerçek verilere daha yakın yapay veriler kullanıldığında daha iyi sonuçlar elde edilebileceği göz önünde bulundurulmalıdır.



KAYNAKLAR

- Abbas, A. K. ve Leonhardt, S., 2008, Neonatal IR-thermography pattern clustering based on ICA algorithm, *Color Image Processing Workshop*, Aachen, Germany.
- Abbas, A. K., Heimann, K., Blazek, V., Orlikowsky, T. ve Leonhardt, S., 2012, Neonatal infrared thermography imaging: analysis of heat flux during different clinical scenarios, *Infrared Physics & Technology*, 55 (6), 538-548.
- Alan, B. ve Nalbantgil, S., 2010, Genetic, cellular and molecular mechanisms of pulmonary arterial hypertension/Pulmoner arteriyel hipertansiyonda genetik, hucresel ve molekuler mekanizmalar, *The Anatolian Journal of Cardiology (Anadolu Kardiyoloji Dergisi)*, 10 (1), 9-13.
- Altman, N. S., 1992, An introduction to kernel and nearest-neighbor nonparametric regression, *The American Statistician*, 46 (3), 175-185.
- Amalu, W., Hobbins, W., Head, J. ve Elliot, R., 2006, Infrared imaging of the breast - An overview, *The Biomedical Engineering Handbook, 3rd ed., Medical Devices and Systems*, 1-21.
- Ammer, K., 2008, The Glamorgan Protocol for recording and evaluation of thermal images of the human body, *Thermology International*, 18 (4), 125-144.
- Anonymous, 2013a, Specification for thermal imagers for human temperature screening. Part 1 : Requirements and test methods. Singapore
- Anonymous, 2013b, Specification for thermal imagers for human temperature screening. Part 2 : Implementation guidelines. Singapore, Standardisation Dept., SPRING Singapore.
- Apgar, V., 2015, A proposal for a new method of evaluation of the newborn infant, *Anesthesia and analgesia*, 120 (5), 1056-1059.
- Arora, N., Martins, D., Ruggerio, D., Tousimis, E., Swistel, A. J., Osborne, M. P. ve Simmons, R. M., 2008, Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer, *The American Journal of Surgery*, 196 (4), 523-526.
- Bach, V., Delanaud, S., Barcat, L., Bodin, E., Tourneux, P. ve Libert, J.-P., 2019, Distal skin vasodilation in sleep preparedness, and its impact on thermal status in preterm neonates, *Sleep Medicine*, 60, 26-30.
- Bagavathiappan, S., Saravanan, T., Philip, J., Jayakumar, T., Raj, B., Karunanithi, R., Panicker, T. M., Korath, P. ve Jagadeesan, K., 2008, Investigation of peripheral vascular disorders using thermal imaging, *The British Journal of Diabetes & Vascular Disease*, 8 (2), 102-104.
- Bahadue, F. L. ve Soll, R., 2012, Early versus delayed selective surfactant treatment for neonatal respiratory distress syndrome, *Cochrane Database of Systematic Reviews*, 11 (11).
- Barnes, R. B., 1963, Thermography of the human body: Infrared-radiant energy provides new concepts and instrumentation for medical diagnosis, *Science*, 140 (3569), 870-877.
- Bouzida, N., Bendada, A. ve Maldague, X. P., 2009, Visualization of body thermoregulation by infrared imaging, *Journal of Thermal Biology*, 34 (3), 120-126.
- Brandt, C. D., Kim, H. W., Vargosko, A. J., Jeffries, B. C., Arrobio, J. O., Rindge, B., Parrott, R. H. ve Chanock, R. M., 1969, Infections in 18,000 infants and children in a controlled study of respiratory tract disease. I. Adenovirus pathogenicity in relation to serologic type and illness syndrome, *American journal of epidemiology*, 90 (6), 484-500.

- Bromley, J., Guyon, I., LeCun, Y., Säckinger, E. ve Shah, R., 1993, Signature verification using a "siamese" time delay neural network, *Advances in neural information processing systems*, 6, 737-744.
- Byrnes, J., 2008, Unexploded ordnance detection and mitigation, Springer Science & Business Media.
- Campbell, M., 1970a, Natural history of coarctation of the aorta, *British Heart Journal*, 32 (5), 633-640.
- Campbell, M., 1970b, Natural history of atrial septal defect, *Heart*, 32 (6), 820-826.
- Caplan, M. S., Russell, T., Xiao, Y., Amer, M., Kaup, S. ve Jilling, T., 2001, Effect of polyunsaturated fatty acid (PUFA) supplementation on intestinal inflammation and necrotizing enterocolitis (NEC) in a neonatal rat model, *Pediatric research*, 49 (5), 647-652.
- Ceylan, M., 2004, Kompleks değerli yapay sinir ağı ile algoritma geliştirilmesi ve uygulanması, Yüksek Lisans, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 154.
- Cherkas, L., Carter, L., Spector, T., Howell, K., Black, C. ve MacGregor, A., 2003, Use of thermographic criteria to identify Raynaud's phenomenon in a population setting, *The Journal of rheumatology*, 30, 720-722.
- Chicco, D., 2021, Siamese neural networks: An overview, *Artificial Neural Networks*, 73-94.
- Christidis, I., Zotter, H., Rosegger, H., Engele, H., Kurz, R. ve Kerbl, R., 2003, Infrared thermography in newborns: the first hour after birth, *Gynäkologisch-geburtshilfliche Rundschau*, 43 (1), 31-35.
- Clark, R. ve Stothers, J., 1980, Neonatal skin temperature distribution using infra-red colour thermography, *The Journal of physiology*, 302 (1), 323-333.
- Cortes, C. ve Vapnik, V., 1995, Support-vector networks, *Machine learning*, 20 (3), 273-297.
- Cosh, J. A. ve Ring, E. F. J., 1970, Thermography and Rheumatology, *Rheumatology*, 10 (7), 342-348.
- Dail, R., Guenther, B. ve Rice, H., 2011, Thermoregulation and thermography in neonatal physiology and disease, *Biological research for nursing*, 13, 274-282.
- Dalla Vecchia, L. K., Grosfeld, J. L., West, K. W., Rescorla, F. J., Scherer, L. R. ve Engum, S. A., 1998, Intestinal atresia and stenosis: a 25-year experience with 277 cases, *Archives of Surgery*, 133 (5), 490-497.
- Egbe, A., Uppu, S., Lee, S., Stroustrup, A., Ho, D. ve Srivastava, S., 2015, Congenital malformations in the newborn population: a population study and analysis of the effect of sex and prematurity, *Pediatrics & Neonatology*, 56 (1), 25-30.
- Ervural, S., Ceylan, M. ve Örnek, A., Haydar, 2020, Yapay zekânın termal görüntüleme üzerine uygulamaları, *Türkiye Klinikleri Radyoloji*, 6-11.
- Ervural, S. ve Ceylan, M., 2021a, Convolutional neural networks-based approach to detect neonatal respiratory system anomalies with limited thermal image, *Traitement du Signal*, 38 (2), 437-442.
- Ervural, S. ve Ceylan, M., 2021b, Overview of artificial intelligence based biomedical applications of infrared thermal imaging, *Journal of Artificial Intelligence in Health Sciences*, 1 (1), 24-34.
- Fei-Fei, L., Fergus, R. ve Perona, P., 2006, One-shot learning of object categories, *IEEE transactions on pattern analysis and machine intelligence*, 28 (4), 594-611.
- Frize, M., Nur, R., Bariciak, E. ve Herry, C., 2013, Infrared imaging and classification of neonates with necrotising enterocolitis, *World Congress on Medical Physics and Biomedical Engineering*, Beijing, China, 1309-1312.

- Goetz, C., Foertsch, D., Schoenberger, J. ve Uhl, E., 2005, Thermography—a valuable tool to test hydrocephalus shunt patency, *Acta neurochirurgica*, 147 (11), 1167-1173.
- Günay, Ş., Eser, İ. ve Kürkçüoğlu, İ. C., 2015, Yenidoğanda pnömotoraks ve yönetimi, *Türkiye Klinikleri Thoracic Surgery-Special Topics*, 6 (1), 8-13.
- Gündoğdu, B., Yusuf, B. ve Saraçlar, M., 2017, Joint learning of distance metric and query model for posteriorgram-based keyword search, *IEEE Journal of Selected Topics in Signal Processing*, 11 (8), 1318-1328.
- Heimann, K., Jergus, K., Abbas, A. K., Heussen, N., Leonhardt, S. ve Orlikowsky, T., 2013, Infrared thermography for detailed registration of thermoregulation in premature infants, *Journal of perinatal medicine*, 1-8.
- Henneke, E. G., Reifsnider, K. L. ve Stinchcomb, W. W., 1979, Thermography—an NDI method for damage detection, *JOM*, 31 (9), 11-15.
- Herry, C. L., Frize, M. ve Bariciak, E., 2011, Assessment of abdominal skin temperature change in premature newborns with NEC compared to healthy controls, *5th European Conference of the International Federation for Medical and Biological Engineering*, 191-194.
- Herschel, W., 1800, XIV. Experiments on the refrangibility of the invisible rays of the sun, *Philosophical Transactions of the Royal Society of London* (90), 284-292.
- Hildebrandt, C., Zeilberger, K., Ring, E. F. J. ve Raschner, C., 2012, The application of medical infrared thermography in sports medicine, *An international perspective on topics in sports medicine and sports injury*, 534.
- Ho, T. K., 1998, The random subspace method for constructing decision forests, *IEEE transactions on pattern analysis and machine intelligence*, 20 (8), 832-844.
- Hug, L., Alexander, M., You, D., Alkema, L. ve for Child, U. I.-a. G., 2019, National, regional, and global levels and trends in neonatal mortality between 1990 and 2017, with scenario-based projections to 2030: a systematic analysis, *The Lancet Global Health*, 7 (6), e710-e720.
- Jeon, M., Park, D., Lee, J., Jeon, H., Ko, M., Kim, S., Choi, Y., Tan, A.-C. ve Kang, J., 2019, ReSimNet: drug response similarity prediction using Siamese neural networks, *Bioinformatics*, 35 (24), 5249-5256.
- Jindal, S., Gupta, G., Yadav, M., Sharma, M. ve Vig, L., 2017, Siamese networks for chromosome classification, *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 72-81.
- Jones, B. F., 1998, A reappraisal of the use of infrared thermal image analysis in medicine, *IEEE transactions on medical imaging*, 17 (6), 1019-1027.
- Karabel, M., Karabel, D., Okur, M. H., Tan, İ., Kelekci, S., Şen, V. ve Uluca, Ü., 2013, Yenidoğan yoğun bakım ünitesinde pnömotoraks gelişen olguların değerlendirilmesi, *Journal of Clinical and Experimental Investigations*, 4 (3), 289-292.
- Karakoç, D. ve Hamaloğlu, E., 2006, İntestinal obstrüksiyonlar, *Türkiye Klinikleri Cerrahi Tıp Bilimleri Dergisi*, 2 (15), 51-63.
- Knobel-Dail, R. B., Holditch-Davis, D., Sloane, R., Guenther, B. D. ve Katz, L. M., 2017, Body temperature in premature infants during the first week of life: Exploration using infrared thermal imaging, *Journal of Thermal Biology*, 69, 118-123.
- Knobel, R. B., Guenther, B. D. ve Rice, H. E., 2011, Thermoregulation and thermography in neonatal physiology and disease, *Biological research for nursing*, 13 (3), 274-282.
- Koch, G., Zemel, R. ve Salakhutdinov, R., 2015, Siamese neural networks for one-shot image recognition, *ICML deep learning workshop*.

- Kohavi, R., 1995, A study of cross-validation and bootstrap for accuracy estimation and model selection, *Ijcai*, 1137-1145.
- Konak, M., Sert, A., Gündüz, M., Soylu, H. ve Uygun, S. S., 2019, Evaluation of congenital anomalies accompanying to gastrointestinal system surgical pathologies, *Cukurova Medical Journal*, 44 (2), 425-430.
- Kontos, M., Wilson, R. ve Fentiman, I., 2011, Digital infrared thermal imaging (DITI) of breast lesions: Sensitivity and specificity of detection of primary breast cancers, *Clinical radiology*, 66, 536-539.
- Kosloske, A., 1994, Epidemiology of necrotizing enterocolitis, *Acta paediatrica*, 83, 2-7.
- Köksal, N., Bayram, Y. ve Durmaz, O., 2002, Geçici takipneli yenidoğan olguların irdelenmesi, *Uludağ Üniversitesi Tıp Fakültesi Dergisi*, 28 (1), 9-12.
- Kramer, M. A., 1991, Nonlinear principal component analysis using autoassociative neural networks, *AIChE journal*, 37 (2), 233-243.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25, 1097-1105.
- Kurath-Koller, S., Litscher, G., Gross, A., Freidl, T., Koestenberger, M., Urlesberger, B. ve Raith, W., 2015, Changes of locoregional skin temperature in neonates undergoing laser needle acupuncture at the acupuncture point large intestine 4, *Evidence-Based Complementary and Alternative Medicine*, 2015, 1-6.
- Lahiri, B., Bagavathiappan, S., Jayakumar, T. ve Philip, J., 2012, Medical applications of infrared thermography: a review, *Infrared Physics & Technology*, 55 (4), 221-235.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- Lippmann, R. P., 1989, Pattern classification using neural networks, *IEEE communications magazine*, 27 (11), 47-50.
- Liu, C.-F., Padhy, S., Ramachandran, S., Wang, V. X., Efimov, A., Bernal, A., Shi, L., Vaillant, M., Ratnanather, J. T. ve Faria, A. V., 2019a, Using deep Siamese neural networks for detection of brain asymmetries associated with Alzheimer's disease and mild cognitive impairment, *Magnetic resonance imaging*, 64, 190-199.
- Liu, X., Zhou, Y., Zhao, J., Yao, R., Liu, B. ve Zheng, Y., 2019b, Siamese convolutional neural networks for remote sensing scene classification, *IEEE Geoscience and Remote Sensing Letters*, 16 (8), 1200-1204.
- Lloyd, J. M., 2013, Thermal imaging systems, Springer Science & Business Media.
- Maldague, X., 2001, Theory and practice of infrared technology for nondestructive testing.
- Marins, J., Fernández-Cuevas, I., Arnaiz-Lastras, J., Fernandes, A. ve Sillero-Quintana, M., 2015, Applications of Infrared Thermography in Sports. A Review, *International Journal of Medicine and Science of Physical Activity and Sport*, 15 (60), 805-824.
- McCallum, A. ve Nigam, K., 1998, A comparison of event models for naive bayes text classification, *AAAI-98 workshop on learning for text categorization*, 41-48.
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5 (4), 115-133.
- McDuffie, L. A., Wakeman, D. ve Warner, B. W., 2010, Diagnosis of esophageal atresia with tracheoesophageal fistula: is there a need for gastrointestinal contrast?, *The Journal of pediatrics*, 156 (5), 852.
- Modest, M. F., 2013, Radiative heat transfer, Academic press.

- Morgan, J. N. ve Sonquist, J. A., 1963, Problems in the analysis of survey data, and a proposal, *Journal of the American statistical association*, 58 (302), 415-434.
- Mosalli, R., Alfaleh, K. ve Paes, B., 2009, Role of prophylactic surgical ligation of patent ductus arteriosus in extremely low birth weight infants: Systematic review and implications for clinical practice, *Annals of pediatric cardiology*, 2, 120-126.
- Nagashima, M., Okamura, T., Shikata, F., Chisaka, T., Takata, H., Ohta, M., Yamamoto, E. ve Higaki, T., 2011, Pulmonary artery banding for neonates and early infants with low body weight, *The Tohoku journal of experimental medicine*, 225 (4), 255-262.
- Neu, J., 1996, Necrotizing enterocolitis: the search for a unifying pathogenic theory leading to prevention, *Pediatric Clinics*, 43 (2), 409-432.
- Ng, W. K., Ng, Y. K. ve Tan, Y. K., 2009, Qualitative study of sexual functioning in couples with erectile dysfunction: prospective evaluation of the thermography diagnostic system, *The Journal of reproductive medicine*, 54 (11-12), 698-705.
- Nilsson, N. J., 2014, Principles of artificial intelligence, Morgan Kaufmann.
- Nur, R., 2014, Identification of thermal abnormalities by analysis of abdominal infrared thermal images of neonatal patients, *Carleton University*.
- Ornek, A. H., Ervural, S. ve Ceylan, M., 2018 of Conference, Determination of correct approaches in evaluation of thermograms, *Ix. Ursi-Türkiye 2018 Bilimsel Kongresi*, KTO Karatay Üniversitesi, Konya.
- Ornek, A. H. ve Ceylan, M., 2019, Comparison of traditional transformations for data augmentation in deep learning of medical thermography, *2019 42nd International Conference on Telecommunications and Signal Processing (TSP)*, 191-194.
- Ornek, A. H., Ceylan, M. ve Ervural, S., 2019, Health status detection of neonates using infrared thermography and deep convolutional neural networks, *Infrared Physics & Technology*, 103, 103044.
- Ornek, A. H., Ervural, S., Ceylan, M., Konak, M., Soylu, H. ve Savasci, D., 2020, Classification of medical thermograms belonging neonates by using segmentation, feature engineering and machine learning algorithms, *Traitement du Signal*, 37 (4), 611-617.
- Oya, A., Asakura, H., Koshino, T. ve Araki, T., 1997, Thermographic demonstration of nonshivering thermogenesis in human newborns after birth: its relation to umbilical gases, *Journal of perinatal medicine*.
- Örnek, A. H. ve Ceylan, M., 2020, Explainable features in classification of neonatal thermograms, *2020 28th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Pomerance, J. J., Lieberman, R. L. ve Ukrainski, C. T., 1977, Neonatal Thermography, *Pediatrics*, 59 (3), 345.
- Rasor, J. S., Zlotta, A. R., Edwards, S. D. ve Schulman, C. C., 1993, Transurethral needle ablation (TUNA): thermal gradient mapping and comparison of lesion size in a tissue model and in patients with benign prostatic hyperplasia, *European urology*, 24, 411-414.
- Rice, H. E., Hollingsworth, C., Bradsher, E., Danko, M. E., Crosby, S. M., Goldberg, R. N., Tanaka, D. ve Dail, R., 2010, Infrared thermal imaging (thermography) of the abdomen in extremely low birthweight infants, *Journal of Surgical Radiology*, 1.
- Ring, E. ve Bacon, P., 1977, Quantitative thermographic assessment of inositol nicotinate therapy in Raynaud's phenomena, *Journal of International Medical Research*, 5 (4), 217-222.
- Ring, E. ve Ammer, K., 2012, Infrared thermal imaging in medicine, *Physiological measurement*, 33 (3), R33.

- Rogalski, A. ve Chrzanowski, K., 2002, Infrared devices and techniques, *Optoelectronics Review*, 10 (2), 111-136.
- Savasci, D., Ornek, A. H., Ervural, S., Ceylan, M., Konak, M. ve Soylu, H., 2019, Classification of unhealthy and healthy neonates in neonatal intensive care units using medical thermography processing and artificial neural network, In: *Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis*, Eds: Elsevier, p. 1-29.
- Savaşci, D. ve Ceylan, M., 2018, Thermal image analysis for neonatal intensive care units (First evaluation results), *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Saxena, A. ve Willital, G., 2008, Infrared thermography: Experience from a decade of pediatric imaging, *European journal of pediatrics*, 167, 757-764.
- Schwartz, R., Elliott, R., Goldberg, G., Govindan, S., Conwell, T. ve Hoekstra, P., 2006, The american academy of thermology. Guidelines for neuromusculoskeletal thermography, *Thermol Int*, 16, 5-9.
- Sherman, R. A., Woerman, A. L. ve Karstetter, K. W., 1996, Comparative effectiveness of videothermography, contact thermography, and infrared beam thermography for scanning relative skin temperature, *Journal of rehabilitation research and development*, 33, 377-386.
- Shevelev, I. A., 1998, Functional imaging of the brain by infrared radiation (thermoencephaloscopy), *Progress in Neurobiology*, 56 (3), 269-305.
- Sillen, U., Hagberg, S., Rubenson, A. ve Werkmäster, K., 1988, Management of esophageal atresia: review of 16 years' experience, *Journal of pediatric surgery*, 23 (9), 805-809.
- Spicer, D. E., Hsu, H. H., Co-Vu, J., Anderson, R. H. ve Fricker, F. J., 2014, Ventricular septal defect, *Orphanet journal of rare diseases*, 9 (1), 1-16.
- Sruthi, S. ve Sasikala, M., 2015, A low cost thermal imaging system for medical diagnostic applications, *2015 International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM)*, 621-623.
- Sun, Z., He, Y., Gritsenko, A., Lendasse, A. ve Baek, S., 2020, Embedded spectral descriptors: learning the point-wise correspondence metric via Siamese neural networks, *Journal of Computational Design and Engineering*, 7 (1), 18-29.
- Taigman, Y., Yang, M., Ranzato, M. A. ve Wolf, L., 2014, Deepface: Closing the gap to human-level performance in face verification, *Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition*, 1701-1708.
- Taylor, A. M., 2008, Cardiac imaging: MR or CT? Which to use when, *Pediatric radiology*, 38, 433.
- Tchervenkova, C. I., Jacobs, J. P., Weinberg, P. M., Aiello, V. D., Béland, M. J., Colan, S. D., Elliott, M. J., Franklin, R. C. G., Gaynor, J. W., Krogmann, O. N., Kurosawa, H., Maruszewski, B. ve Stellin, G., 2006, The nomenclature, definition and classification of hypoplastic left heart syndrome, *Cardiology in the Young*, 16 (4), 339-368.
- Tharwat, A., 2020, Classification assessment methods, *Applied Computing and Informatics*.
- Thiolliere, R., Dunbar, E., Synnaeve, G., Versteegh, M. ve Dupoux, E., 2015, A hybrid dynamic time warping-deep neural network architecture for unsupervised acoustic modeling, *Sixteenth Annual Conference of the International Speech Communication Association*.

- Thompson, J. E., Simpson, T. L. ve Caulfield, J. B., 1978, Thermographic tumor detection enhancement using microwave heating, *IEEE Transactions on Microwave Theory and Techniques*, 26 (8), 573-580.
- Topalidou, A., Ali, N., Sekulic, S. ve Downe, S., 2019, Thermal imaging applications in neonatal care: a scoping review, *BMC pregnancy and childbirth*, 19 (1), 1-14.
- Utkin, L., Zhuk, Y. A. ve Zaborovsky, V., 2017, An anomalous behavior detection of a robot system by using a hierarchical Siamese neural network, *2017 XX IEEE International Conference on Soft Computing and Measurements (SCM)*, 630-634.
- van Lennep, M., Singendonk, M. M. J., Dall'Oglio, L., Gottrand, F., Krishnan, U., Terheggen-Lagro, S. W. J., Omari, T. I., Benninga, M. A. ve van Wijk, M. P., 2019, Oesophageal atresia, *Nature Reviews Disease Primers*, 5 (1), 26.
- Vyas, H. V., Greenberg, S. B. ve Krishnamurthy, R., 2012, MR imaging and CT evaluation of congenital pulmonary vein abnormalities in neonates and infants, *Radiographics*, 32 (1), 87-98.
- Walker, S. H. ve Duncan, D. B., 1967, Estimation of the probability of an event as a function of several independent variables, *Biometrika*, 54 (1-2), 167-179.
- Wang, J., Fang, Z., Lang, N., Yuan, H., Su, M.-Y. ve Baldi, P., 2017, A multi-resolution approach for spinal metastasis detection using deep Siamese neural networks, *Computers in biology and medicine*, 84, 137-146.
- White, R., Blainey, A., Harrison, K. ve Clarke, S., 1981, Causes of pneumonia presenting to a district general hospital, *Thorax*, 36 (8), 566-570.
- Will, R., Ring, E. F. J., Clarke, A. ve Maddison, P., 1992, Infrared thermography: What is its place in rheumatology in the 1990s?, *British journal of rheumatology*, 31, 337-344.
- Zeng, X., Chen, H., Luo, Y. ve Ye, W., 2019, Automated diabetic retinopathy detection based on binocular siamese-like convolutional neural network, *IEEE Access*, 7, 30744-30753.
- Zheng, W., Yang, L., Genco, R. J., Wactawski-Wende, J., Buck, M. ve Sun, Y., 2019, SENSE: Siamese neural network for sequence embedding and alignment-free comparison, *Bioinformatics*, 35 (11), 1820-1828.
- Zhong-Shan, D. ve Jing, L., 2005, Enhancement of thermal diagnostics on tumors underneath the skin by induced evaporation, *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, 7525-7528.
- Zou, Y., Li, J., Chen, X. ve Lan, R., 2018, Learning Siamese networks for laser vision seam tracking, *JOSA A*, 35 (11), 1805-1813.